

Maestría en

INTELIGENCIA ARTIFICIAL APLICADA

Trabajo previo a la obtención de título de
Magister en Inteligencia Artificial Aplicada

AUTORES:

Cervantes Bonilla Guillermo Sebastián

Garcia Romero Mario Dario

Oscullo Ñacato Bryan Wladimir

TUTOR/ES:

Juan Fernando López Tito

Karla Estefanía Mora Cajas

Comparación de modelos estadísticos de series temporales, de aprendizaje automático y de aprendizaje profundo para la predicción de precios mayoristas agrícolas en Ecuador, incorporando variables exógenas económicas y sectoriales

Certificación de autoría

Nosotros, **Cervantes Bonilla Guillermo Sebastián, Garcia Romero Mario Dario y Oscullo Ñacato Bryan Wladimir**, declaramos bajo juramento que el trabajo aquí descrito es de nuestra autoría; que no ha sido presentado anteriormente para ningún grado o calificación profesional y que se ha consultado la bibliografía detallada.

Cedemos nuestros derechos de propiedad intelectual a la Universidad Internacional del Ecuador (UIDE), para que sea publicado y divulgado en internet, según lo establecido en la Ley de Propiedad Intelectual, su reglamento y demás disposiciones legales.



Firma
Cervantes Bonilla Guillermo Sebastián



Firma
Garcia Romero Mario Dario



Firma
Oscullo Ñacato Bryan Wladimir

Autorización de Derechos de Propiedad Intelectual

Nosotros, **Cervantes Bonilla Guillermo Sebastián, Garcia Romero Mario Dario y Oscullo Ñacato Bryan Wladimir**, en calidad de autores del trabajo de investigación titulado ***Comparación de modelos estadísticos de series temporales, de aprendizaje automático y de aprendizaje profundo para la predicción de precios mayoristas agrícolas en Ecuador, incorporando variables exógenas económicas y sectoriales***, autorizamos a la Universidad Internacional del Ecuador (UIDE) para hacer uso de todos los contenidos que nos pertenecen o de parte de los que contiene esta obra, con fines estrictamente académicos o de investigación. Los derechos que como autores nos corresponden, lo establecido en los artículos 5, 6, 8, 19 y demás pertinentes de la Ley de Propiedad Intelectual y su Reglamento en Ecuador.

D. M. Quito, julio 2026



Firma
Cervantes Bonilla Guillermo Sebastián




Firma
Garcia Romero Mario Dario



Firma
Oscullo Ñacato Bryan Wladimir

Aprobación de dirección y coordinación del programa

Nosotros, **Alejandro Cortés López y Karla Estefanía Mora Cajas**, declaramos que: **Cervantes Bonilla Guillermo Sebastián, Garcia Romero Mario Dario y Oscullo Ñacato Bryan Wladimir** son los autores exclusivos de la presente investigación y que ésta es original, auténtica y personal de ellos.



Alejandro Cortés López Director de la
Maestría en Inteligencia Artificial
Aplicada



Karla Estefanía Mora Cajas
Coordinadora de la
Maestría en Inteligencia Artificial Aplicada

Dedicatoria

A mi familia. Por su comprensión, apoyo y motivación constante durante este proceso. Cada uno de mis logros es también un reflejo de su esfuerzo y la confianza puesta en mí.

A mi esposa. Por acompañarme en cada etapa, por creer en mí y ser mi inspiración para seguir creciendo. Este logro forma parte del futuro que construimos juntos.

A mi abuelita. Por tus enseñanzas, tu amor y tu recuerdo, que continúan acompañándome. Dedico este logro a tu memoria, siempre ocuparás un lugar especial en mi vida.

Bryan Wladimir Oscullo Ñacato

Primeramente, a Dios por darme la salud, sabiduría y perseverancia para permitirme alcanzar esta meta.

A mis padres, por su apoyo incondicional, sus consejos, y por ser el pilar principal de mi formación profesional y personal.

A mi familia, por la motivación, comprensión y paciencia en este camino para seguir adelante.

A mis compañeros y amigos, que de una u otra forma me brindaron apoyo, y compartieron conmigo a lo largo de este proceso académico.

Finalmente, a mí, por el esfuerzo y la constancia demostrada a lo largo de este logro. Siendo este trabajo un resultado del compromiso y dedicación invertidos para alcanzar este objetivo.

Mario Dario Garcia Romero

A Dios, por ser mi guía y concederme la salud, la sabiduría y la templanza necesarias para culminar con éxito este camino.

A mis padres, por su amor y apoyo incondicional. Gracias por sus consejos y por ser el pilar fundamental en mi formación profesional y humana.

A mi pareja y mi familia, por su comprensión, paciencia y motivación constante en los momentos más exigentes de este proceso.

Finalmente, a mí, por la constancia, la disciplina y el compromiso demostrados. Este logro es la recompensa del esfuerzo invertido para alcanzar una meta más.

Guillermo Sebastián Cervantes Bonilla

Agradecimientos

Expreso mi agradecimiento a la Universidad Internacional del Ecuador **UIDE** y la Escuela Internacional de Gerencia **EIG** por brindarme la oportunidad de fortalecer mi formación profesional mediante esta maestría.

Agradezco a los docentes y coordinadores, quienes, mediante sus conocimientos, experiencia, orientación y recomendaciones, aportaron tanto a mi proceso de aprendizaje como al desarrollo de este estudio. Sus observaciones durante las diferentes etapas del trabajo permitieron fortalecer su contenido, metodología y presentación final.

Finalmente, agradezco a todas las personas que, de manera directa o indirecta, contribuyeron al cumplimiento de este objetivo académico.

Bryan Wladimir Oscullo Ñacato

Agradezco a Dios por brindarme de vida, la salud, la fortaleza y el conocimiento que me permitieron finalizar este periodo fundamental de mi formación profesional.

A mis padres y a mi familia, por su confianza, comprensión, amor y apoyo a lo largo de todo este proceso, su sacrificio, esfuerzo y motivación constante fueron esenciales.

A mis maestros, amigos y compañeros, por la colaboración, el apoyo y los momentos vividos en esta etapa, que convirtieron este trayecto en una experiencia enriquecedora.

Por último, expreso mi gratitud a todas las personas que han colaborado en la realización de esta investigación y en la obtención de este importante objetivo académico.

Mario Dario Garcia Romero

Dedico este trabajo, en primer lugar, a Dios, por ser mi guía en cada paso de mi vida y por concederme la fortaleza necesaria para alcanzar esta meta.

A mi familia, quienes han sido mi mayor inspiración y el pilar fundamental de mi crecimiento personal y profesional. Gracias por su amor, paciencia, comprensión y apoyo incondicional durante cada etapa de este camino.

A todas aquellas personas que creen en el poder del conocimiento, la investigación y la innovación como herramientas para transformar la sociedad. Que este trabajo represente un pequeño aporte al desarrollo de soluciones tecnológicas orientadas al fortalecimiento del sector agropecuario y al bienestar de quienes dependen de él.

Con gratitud y satisfacción, dedico este logro como el resultado del esfuerzo, la perseverancia y el compromiso con la excelencia académica.

Guillermo Sebastián Cervantes Bonilla

Resumen

La variación de los precios agrícolas representa un desafío para la planificación productiva y comercial, debido a factores temporales, territoriales, económicos y productivos. El objetivo de este estudio fue evaluar comparativamente modelos estadísticos de series temporales, de aprendizaje automático y de aprendizaje profundo para predecir precios de productos mayoristas agrícolas en Ecuador, analizando el efecto de incorporar variables exógenas económicas y sectoriales. Se estudiaron a Papa Superchola, Tomate Riñón de Invernadero y Maracuyá.

Se utilizaron datos del SIPA (Sistema de Información Pública Agropecuaria), como: precios de mercados mayoristas, precio productor, fertilizantes, IPC de alimentos, inflación e índices sectoriales, para construir datasets con estructura producto-provincia-fecha. Se entrenaron y evaluaron tres enfoques: SARIMAX, XGBoost y LSTM, mediante una configuración base sin variables exógenas y una configuración con dichas variables, permitiendo evaluar de forma controlada su aporte al desempeño predictivo.

La evaluación utilizó una división temporal del 80% para desarrollo y 20% para prueba, con validación mediante ventanas expansivas. La selección operacional por producto se realizó considerando el RMSE promedio en pronósticos de uno a tres meses. XGBoost presentó el mejor desempeño operacional para Maracuyá y Papa Superchola, mientras que LSTM obtuvo el mejor resultado para Tomate Riñón de Invernadero.

La incorporación de variables exógenas produjo mejoras estadísticamente significativas en cinco de las nueve combinaciones producto-modelo evaluadas, evidenciando que su aporte depende del producto y del enfoque de modelado. Finalmente, se implementó un prototipo web para la consulta y visualización de pronósticos por producto, provincia y horizonte temporal.

Palabras clave: predicción de precios agrícolas, aprendizaje automático, aprendizaje profundo, SARIMAX, XGBoost, LSTM, variables exógenas.

Abstract

Agricultural price volatility represents a challenge for productive and commercial planning due to temporal, territorial, economic, and production-related factors. The objective of this research was to comparatively evaluate statistical time series, machine learning, and deep learning models for predicting wholesale agricultural prices in Ecuador, analyzing the effect of incorporating economic and sectorial exogenous variables. Papa Superchola, Tomate Riñón de Invernadero and Maracuyá were analyzed.

Data from SIPA (Sistema de Información Pública Agropecuaria), including wholesale market prices, producer prices, fertilizer prices, food CPI, inflation, and sectoral indices, were used to construct datasets structured by product-province-date. Three approaches were trained and evaluated: SARIMAX, XGBoost and LSTM, using a baseline configuration without exogenous variables and a configuration incorporating these variables, allowing their contribution to predictive performance to be evaluated in a controlled manner.

Evaluation was based on a temporal split of 80% for development and 20% for testing, with expanding-window validation. Operational model selection for each product was based on the average RMSE for forecast from one to three months ahead. XGBoost achieved the best operational performance for Maracuyá and Papa Superchola, while LSTM obtained the best result for Tomate Riñón de Invernadero.

The incorporation of exogenous variables produced statistically significant improvements in five of the nine product-model combinations evaluated, indicating that their contribution depends on both the product and the modeling approach. Finally, a web prototype was implemented for consulting and visualizing forecasts by product, province, and forecast horizon.

Keywords: agricultural price forecasting, machine learning, deep learning, SARIMAX, XGBoost, LSTM, exogenous variables

Tabla de Contenidos

Certificación de autoría	i
Autorización de Derechos de Propiedad Intelectual.....	ii
Acuerdo de confidencialidad	¡Error! Marcador no definido.
Aprobación de dirección y coordinación del programa	iii
Dedicatoria.....	iii
Agradecimientos	vi
Resumen	viii
Abstract.....	ix
Tabla de Contenidos	x
Lista de Tablas	xiii
Lista de Figuras	xiv
Capítulo 1. Introducción	1
Definición del Proyecto	1
Justificación e Importancia del Trabajo de Investigación.....	3
Alcance	5
Objetivos.....	6
<i>Objetivo General</i>	6
<i>Hipótesis</i>	6
<i>Objetivos Específicos</i>	7
Capítulo 2. Revisión de Literatura.....	8
Estado del Arte.....	8
Marco Teórico	13
<i>Mercado agrícola y comportamiento de precios</i>	13
<i>Series temporales y predicción de precios agrícolas</i>	15
<i>Modelos estadísticos para pronóstico</i>	17

<i>Modelos de aprendizaje automático aplicados a la predicción</i>	18
<i>Redes neuronales recurrentes y modelos de aprendizaje profundo</i>	20
<i>Variables exógenas en la predicción de precios agrícolas</i>	21
<i>Evaluación del desempeño de modelos predictivos</i>	23
<i>Visualización de resultados predictivos</i>	27
Terminología	28
Capítulo 3. Desarrollo	31
Desarrollo del Trabajo	31
Descripción del Dataset	32
Preparación y Procesamiento de Datos	34
<i>Integración de fuentes de datos</i>	35
<i>Limpieza y depuración de datos</i>	38
<i>Transformación y construcción de variables</i>	41
<i>División cronológica de entrenamiento y prueba</i>	43
Metodología de Análisis o Modelo	45
<i>Enfoque comparativo de modelado predictivo</i>	46
<i>Modelos seleccionados para la comparación</i>	47
<i>Configuración experimental</i>	48
<i>Entrenamiento de los modelos</i>	49
<i>Métricas y criterios para la comparación de modelos</i>	51
<i>Consideraciones para el desarrollo del prototipo web</i>	53
Capítulo 4. Análisis de Resultados	56
Presentación general de resultados	56
Análisis descriptivo de los precios	57
Interpretabilidad de XGBoost	58
Efecto de las variables exógenas	60

Evaluación comparativa de modelos	61
Análisis de resultados por producto	63
<i>Papa Superchola</i>	63
<i>Tomate Riñón de Invernadero</i>	64
<i>Maracuyá</i>	65
Selección operacional de modelos por producto	66
Análisis complementario por provincia	67
Precisión direccional como análisis complementario	72
Análisis por horizonte de pronóstico	73
Resultados del prototipo web.....	74
Discusión de resultados	76
Capítulo 5. Conclusiones y Recomendaciones.....	79
Conclusiones	79
Recomendaciones	81
Referencias Bibliográficas.....	84
Apéndice A. Análisis provincial para Maracuyá	90
Apéndice B. Análisis provincial para Papa Superchola	92
Apéndice C. Análisis provincial para Tomate Riñón de Invernadero	96
Apéndice D. Repositorios Digitales	98

Lista de Tablas

Tabla 1	<i>Síntesis comparativa de estudios relacionados con la predicción de precios agrícolas ..</i>	11
Tabla 2	<i>Métricas de evaluación de modelos predictivos</i>	26
Tabla 3	<i>Criterios de evaluación del desempeño predictivo</i>	26
Tabla 4	<i>Definiciones operativas relacionadas con el estudio</i>	28
Tabla 5	<i>Características generales de los datasets finales por producto</i>	33
Tabla 6	<i>Resumen cuantitativo del preprocesamiento por producto</i>	40
Tabla 7	<i>Esquema de partición temporal para entrenamiento, validación y prueba</i>	45
Tabla 8	<i>Estructura del enfoque comparativo de modelado predictivo</i>	46
Tabla 9	<i>Modelos seleccionados para la comparación</i>	47
Tabla 10	<i>Configuración experimental por modelo</i>	49
Tabla 11	<i>Configuración general de entrenamiento por modelo</i>	50
Tabla 12	<i>Criterios para evaluación y comparación de modelos</i>	52
Tabla 13	<i>Estadísticas descriptivas generales de precios por producto</i>	57
Tabla 14	<i>Importancia relativa de los grupos de variables en XGBoost</i>	59
Tabla 15	<i>Efecto de la incorporación de variables exógenas sobre el RMSE</i>	60
Tabla 16	<i>Resultados comparativos de los modelos con variables exógenas</i>	61
Tabla 17	<i>Desempeño operacional de los modelos con variables exógenas por producto</i>	66
Tabla 18	<i>Modelo con menor RMSE por provincia para Maracuyá</i>	68
Tabla 19	<i>Modelo con menor RMSE por provincia para Papa Superchola</i>	69
Tabla 20	<i>Modelo con menor RMSE por provincia para Tomate Riñón de Invernadero</i>	70
Tabla 21	<i>RMSE por producto, modelo y horizonte de pronóstico</i>	73

Lista de Figuras

Figura 1	<i>Proceso de integración de las fuentes de datos del SIPA.....</i>	35
Figura 2	<i>Integración de variables nacionales mediante la fecha.....</i>	36
Figura 3	<i>Estrategia jerárquica de integración de las variables de fertilizantes</i>	37
Figura 4	<i>Proceso de estandarización de nombres para la integración de las fuentes de datos....</i>	38
Figura 5	<i>Proceso de tratamiento de valores faltantes en el dataset integrado</i>	39
Figura 6	<i>Proceso de consolidación de registros duplicados y preservación de valores atípicos..</i>	40
Figura 7	<i>Proceso de transformación y normalización de variables.....</i>	41
Figura 8	<i>Proceso de construcción de variables temporales y exógenas</i>	43
Figura 9	<i>Arquitectura del prototipo web para la consulta de predicciones</i>	54
Figura 10	<i>Evolución mensual del precio promedio de mercado por producto agrícola</i>	58
Figura 11	<i>Comparación de precios reales y predichos para Papa Superchola</i>	63
Figura 12	<i>Comparación de precios reales y predichos para Tomate Riñón de Invernadero</i>	64
Figura 13	<i>Comparación de precios reales y predichos para Maracuyá</i>	65
Figura 14	<i>Comparación de precios reales y predichos para Maracuyá en Santa Elena</i>	68
Figura 15	<i>Comparación de precios reales y predichos para Papa Superchola en Azuay.....</i>	70
Figura 16	<i>Comparación de precios reales y predichos para Tomate Riñón de Invernadero en Cotopaxi</i>	71
Figura 17	<i>Comparación entre RMSE y Directional Accuracy por producto y modelo</i>	72
Figura 18	<i>Pantalla de selección de producto, provincia y horizonte de predicción</i>	74
Figura 19	<i>Resultado de la predicción.....</i>	75
Figura 20	<i>Métricas de desempeño mostradas en el prototipo.....</i>	76

Capítulo 1. Introducción

Definición del Proyecto

Los productores, distribuidores y comerciantes de productos agrícolas en el Ecuador enfrentan altos niveles de incertidumbre debido a la volatilidad de los precios mayoristas (MAG, 2024), lo que dificulta la toma de decisiones comerciales, particularmente en la planificación de compras, ventas e inventarios. Esta situación puede generar ineficiencias en la cadena agroalimentaria, especialmente en contextos donde las variaciones de precios son frecuentes y difíciles de anticipar (FAO & IFPRI, 2023). En este escenario, la predicción de precios agrícolas se convierte en una herramienta relevante para apoyar procesos de planificación y gestión del sector agro-comercial.

La volatilidad de los precios no depende únicamente de su comportamiento histórico, sino también de factores económicos y productivos externos que influyen en la dinámica del mercado. Entre estos factores se encuentran variables relacionadas con la inflación, costos de producción, precios al productor y comportamiento general del sector agropecuario. En ese sentido, estudios como el de (F. Sun et al., 2023) sostienen que la incorporación de estas variables exógenas permite comprender mejor la dinámica del mercado y mejorar la predicción de precios agrícolas en escenarios complejos y cambiantes.

En el Ecuador, los mercados mayoristas representan espacios estratégicos para el análisis del comportamiento de los precios agrícolas, debido a que concentran información relevante sobre la dinámica comercial y de abastecimiento del país (MAGP, 2026). En este contexto, el presente estudio considera información proveniente de los principales mercados mayoristas del país, como el Mercado Mayorista de Quito, la Terminal de Transferencia de Víveres de Guayaquil y el Mercado Mayorista Terminal el Arenal de Cuenca, por su relevancia dentro de la comercialización agrícola nacional y la disponibilidad de registros históricos comparables (MAG, 2019).

La selección de los productos agrícolas considerados en el estudio responde a criterios de disponibilidad, continuidad y calidad de la información. En esta fase de la investigación se toman como productos de análisis a Papa Superchola, Tomate Riñón de Invernadero y Maracuyá, debido a que presentan un mayor número de registros históricos, presencia sostenida en las distintas fuentes de información, cobertura territorial en varias provincias y continuidad temporal suficiente para construir series útiles para modelos predictivos. El conjunto de datos final mantiene una estructura multivariada y temporalmente consistente, lo que facilita el entrenamiento y la evaluación de los modelos predictivos.

Respecto a las variables explicativas, solo se incluyen variables exógenas que cumplan con criterios de consistencia en el tiempo, compatibilidad geográfica, relevancia económica y cobertura adecuada. Entre ellas figuran los precios al productor a nivel provincial y nacional, precios promedio de fertilizantes, el IPC de alimentos, indicadores de inflación mensual, anual y acumulada, además de métricas agregadas del sector agropecuario como el IBC, el IPM y el IPP-N. También se incorporan variables temporales derivadas, rezagos y promedios móviles, con el fin de captar patrones estacionales y efectos de memoria temporal en las series analizadas.

El presente trabajo propone comparar modelos estadísticos de series temporales, modelos de aprendizaje automático y modelos de aprendizaje profundo para la predicción de precios mayoristas agrícolas, integrando series históricas con variables exógenas económicas y sectoriales. Los estudios de (Gu et al., 2022) y (Nayak et al., 2024) evidencian que los enfoques multivariados ofrecen resultados favorables en la predicción de precios agrícolas al incorporar variables que influyen en la dinámica del mercado.

A partir del problema expuesto, se plantea como pregunta de investigación: ¿Cómo influye la incorporación de variables exógenas económicas y sectoriales en el desempeño predictivo de los modelos para la estimación de precios mayoristas de productos agrícolas en Ecuador? De manera

complementaria, se analizarán las diferencias de desempeño entre los enfoques evaluados y su comportamiento en horizontes de pronóstico de uno a tres meses.

Finalmente, los modelos evaluados serán integrados en un prototipo web interactivo para la consulta y visualización de pronósticos por producto y provincia. Aunque su implementación se limita a los productos y provincias definidos en el estudio, la metodología desarrollada podría adaptarse posteriormente a otros productos, provincias o mercados que dispongan de información histórica comparable y estructurada adecuadamente para el modelado predictivo.

Justificación e Importancia del Trabajo de Investigación

La predicción de precios de productos agrícolas representa una necesidad importante para los involucrados en la cadena agroalimentaria, debido a que la volatilidad de los precios mayoristas aumenta la incertidumbre en la toma de decisiones comerciales, como planificación de compras, ventas e inventarios; inclusive se pueden generar pérdidas, desabastecimientos o excedentes no planificados (Mustafa et al., 2024). Los principales afectados suelen ser productores, distribuidores, pequeños y medianos comerciantes, quienes, usualmente, no cuentan con herramientas analíticas y tecnológicas que les permitan anticipar el comportamiento del mercado (Peña-Holguín et al., 2025).

Esta problemática resulta relevante en Ecuador, donde el sector agropecuario es un componente estratégico de la economía nacional aportando un 8.6% al Producto Interno Bruto en 2025 (SIPA, 2025). La falta de herramientas predictivas limita la capacidad de planificación de siembras, compras y ventas, lo que puede generar pérdidas y desaprovechamiento de oportunidades comerciales. En esta fase del estudio, la Papa Superchola, el Tomate Riñón de Invernadero y la Maracuyá se adoptan como productos de referencia inicial debido a la disponibilidad y continuidad de información histórica, cobertura territorial y consistencia temporal de sus registros, características necesarias para el desarrollo y evaluación de modelos predictivos.

Desde una perspectiva metodológica, la comparación entre modelos estadísticos de series temporales y modelos basados en aprendizaje profundo y aprendizaje automático puede aportar evidencia relevante sobre el desempeño de distintos enfoques predictivos aplicados a mercados agrícolas ecuatorianos, considerando configuraciones con y sin variables exógenas económicas y sectoriales. Con esta propuesta se busca distinguir si las mejoras en los pronósticos provienen de la información adicional que se incorpora o de las capacidades propias de cada algoritmo. Las variables exógenas consideradas son: precio productor, fertilizantes, IPC, inflación e índices sectoriales; en lugar de dar por hecho que incluirlas mejora automáticamente los pronósticos, este estudio evalúa su impacto real mediante pruebas experimentales.

Estos resultados podrían apoyar en la toma de decisiones de compra y venta, fortalecer la gestión de inventarios y contribuir a una mejor planificación productiva y comercial (Guindani et al., 2024). Además, de manera indirecta, una mayor disponibilidad de información podría favorecer procesos de comercialización más eficientes y coordinados, con posibles efectos positivos sobre la estabilidad del abastecimiento (FAO, 2024), y sobre la capacidad de anticipar tendencias de precios en los mercados locales (Avesani et al., 2021).

El proyecto aporta evidencia aplicada sobre el uso de modelos de series temporales, aprendizaje automático y aprendizaje profundo en la predicción de precios mayoristas agrícolas en Ecuador, contribuyendo a un campo en el que aún existe espacio para ampliar estudios contextualizados a los mercados latinoamericanos (Noboa et al., 2022). Además, el desarrollo de un prototipo funcional puede demostrar la posibilidad de traducir modelos predictivos en herramientas de consulta accesibles para usuarios no especializados, favoreciendo la transferencia del conocimiento y el uso de información analítica en la toma de decisiones en el sector productivo (FAO et al., 2024).

La viabilidad de este estudio se sustenta en la disponibilidad de datos históricos, obtenidos principalmente del Sistema de Información Pública Agropecuaria (SIPA, 2026a) y

complementados con otras fuentes oficiales que aportan indicadores económicos y sectoriales. Con esta información es posible construir conjuntos de datos organizados con estructura temporal y territorial adecuada para entrenar y evaluar los modelos. Además, el uso de herramientas computacionales de libre acceso facilita la implementación reproducible de los procedimientos, entrenamiento, validación y evaluación.

En consecuencia, la presente investigación se justifica por su relevancia económica y sectorial, por su potencial para aportar evidencia comparativa sobre distintos modelos predictivos aplicados a los mercados mayoristas agrícolas y por su viabilidad metodológica, respaldada por la disponibilidad de datos oficiales y de técnicas de modelado apropiadas para abordar el problema planteado.

Alcance

El presente trabajo se centrará en la comparación de modelos estadísticos de series temporales, aprendizaje automático y aprendizaje profundo para la predicción de precios mayoristas de productos agrícolas en Ecuador, incorporando variables exógenas económicas y sectoriales. Como casos de estudio inicial se seleccionan Papa Superchola, Tomate Riñón de Invernadero y Maracuyá, elegidos por la disponibilidad, continuidad y consistencia temporal de sus registros históricos. La cobertura temporal de los productos inicia en enero de 2017 y varía según la disponibilidad de información: para Papa Superchola comprende hasta septiembre de 2022, mientras que para Tomate Riñón de Invernadero y Maracuyá se extiende hasta febrero de 2026.

En cuanto a la metodología, el estudio contempla la comparación de tres enfoques predictivos representados por SARIMAX, XGBoost y LSTM. Cada uno se evalúa mediante una configuración base, que toma en cuenta solo la información histórica del precio, y una configuración ampliada con variables exógenas relacionadas con precio productor, fertilizantes, IPC, inflación e índices sectoriales. Esta estructura permite analizar el aporte de la información

exógena dentro de cada modelo, y comparar el rendimiento entre modelos mediante un esquema de validación temporal. Se consideran pronósticos de corto plazo en horizontes de uno a tres meses.

El alcance se limita a los productos, provincias, periodos y variables disponibles en las fuentes utilizadas, por lo que sus resultados no pretenden cubrir todos los mercados agrícolas del país, ni incorporar todos los factores que podrían influir en la formación de precios, como variables climáticas, logísticas o políticas. Para horizontes futuros, las variables exógenas no se pronostican de manera independiente, sino que se mantienen en su último valor conocido, una decisión a ser tomada en cuenta al interpretar los pronósticos.

Asimismo, se desarrolla un prototipo web de carácter funcional y demostrativo, orientado a la consulta y visualización de pronósticos por producto, provincia y horizonte temporal, sin funcionar como una plataforma transaccional ni como un sistema integral de gestión comercial.

Objetivos

Objetivo General

Evaluar comparativamente el desempeño de modelos estadísticos de series temporales, de aprendizaje automático y de aprendizaje profundo para la predicción de precios mayoristas de productos agrícolas en Ecuador. La comparación se realiza mediante configuraciones con y sin variables exógenas económicas y sectoriales, considerando un esquema de validación temporal y horizontes de pronóstico de corto plazo, tomando como casos de estudio iniciales Papa Superchola, Tomate Riñón de Invernadero y Maracuyá.

Hipótesis

La integración de variables exógenas económicas y sectoriales, como precio productor, precios de fertilizantes, IPC, inflación e índices sectoriales, mejora el desempeño predictivo de cada familia de modelos respecto de su correspondiente configuración base sin dichas variables.

Objetivos Específicos

- Recopilar, depurar e integrar series temporales de precios mayoristas y variables exógenas económicas y sectoriales para Papa Superchola, Tomate Riñón de Invernadero y Maracuyá, a partir de las fuentes de información seleccionadas.
- Diseñar, entrenar y validar modelos estadísticos de series temporales, de aprendizaje automático y de aprendizaje profundo bajo configuraciones con y sin variables exógenas, aplicando procedimientos de selección de parámetros e hiperparámetros que respeten la estructura temporal de los datos.
- Evaluar el aporte de las variables exógenas mediante la comparación de cada modelo con su correspondiente configuración base y analizar comparativamente el desempeño de las configuraciones con exógenas, utilizando métricas predictivas, procedimientos estadísticos y horizontes de pronóstico de uno a tres meses.
- Implementar un prototipo web interactivo que integre los modelos seleccionados para cada producto y permite consultar y visualizar pronósticos de corto plazo por producto, provincia y horizonte temporal.

Capítulo 2. Revisión de Literatura

Estado del Arte

En los últimos años, la predicción de precios de productos agrícolas ha ganado relevancia en la literatura especializada, tanto por su utilidad para analizar la dinámica de los mercados agroalimentarios como por su potencial para fortalecer la toma de decisiones de los distintos actores de la cadena de comercialización. Sin embargo, diversos estudios plantean esta predicción como un problema complejo de series temporales, debido a la influencia simultánea de factores como la volatilidad del mercado, la estacionalidad, las variaciones a corto plazo y la presencia de comportamientos no lineales. En ese sentido, estudios como los de (C. Sun et al., 2023) y (Jaiswal et al., 2022) coinciden en que los precios agrícolas presentan patrones complejos, no lineales y cambiantes, por lo que su modelado requiere técnicas que puedan capturar dependencias temporales y cambios abruptos en los datos.

Esta complejidad también es reconocida por (Yin et al., 2020), quienes señalan que los precios de productos hortícolas presentan características no lineales y no estacionarias. De forma similar, el estudio de (Ryu et al., 2023) destaca el impacto de eventos críticos y dispersos en las series temporales agrícolas. Asimismo, (Min et al., 2025) muestran que las fluctuaciones de corto plazo y la interacción entre múltiples variables afectan de manera relevante en el rendimiento predictivo. En conjunto, estos hallazgos confirman que la predicción de precios agrícolas debe tratarse como un fenómeno dinámico y con alta sensibilidad a las variaciones del entorno, y no como un problema lineal o estable.

Dada la complejidad que presentan las series de precios agrícolas, la literatura ha demostrado un interés creciente en el uso de modelos estadísticos de series temporales, de aprendizaje automático y de aprendizaje profundo para abordar la predicción. Dentro de los enfoques estadísticos, modelos de la familia ARIMA continúan siendo una referencia metodológica por su utilidad en el análisis de patrones temporales y su capacidad para establecer

líneas base de comparación (Guindani et al., 2024). Aunque su desempeño puede verse limitado ante relaciones no lineales o cambios estructurales en las series, su inclusión resulta pertinente en estudios comparativos, ya que permite evaluar si los modelos más avanzados ofrecen mejoras reales frente a un enfoque tradicional.

Por su parte, los modelos de aprendizaje automático han ganado relevancia en la predicción de precios agrícolas por su capacidad para capturar relaciones no lineales y aprovechar variables explicativas adicionales. En particular, XGBoost ha sido utilizado en problemas predictivos gracias a su flexibilidad, robustez y capacidad para manejar múltiples variables de entrada, lo que lo convierte en una alternativa adecuada cuando se incorporan variables exógenas económicas o sectoriales (Manogna et al., 2025). A diferencia de los modelos estadísticos tradicionales, este tipo de enfoque permite aprovechar información adicional al comportamiento histórico de la serie, como indicadores de precios, costos de insumos o variables de contexto comercial.

En el campo del aprendizaje profundo, las redes LSTM han adquirido relevancia como una técnica adecuada para el modelado de series temporales agrícolas, debido a su capacidad para capturar dependencias secuenciales y patrones temporales complejos. Estudios como los de (Tami & Owda, 2024; F. Wang et al., 2021) demuestran que las arquitecturas basadas en RNN y LSTM presentan un desempeño favorable en contextos de alta volatilidad. Asimismo, estudios como los de (Adi & Sudianto, 2022; Indra Sanjaya & Heksaputra, 2020) respaldan la aplicabilidad de las redes LSTM en la predicción de precios agrícolas en mercados mayoristas, lo que justifica su incorporación como modelo representativo del aprendizaje profundo en estudios comparativos.

Estudios recientes han ido más allá del empleo de redes LSTM tradicionales y han incorporado variantes metodológicas orientadas a mejorar el rendimiento predictivo en series agrícolas complejas. Tanto (C. Sun et al., 2023) como (Gu et al., 2022), (Lagarteja & Taracatac, 2023) y (Yin et al., 2020) evidencian que la combinación de técnicas de descomposición,

mecanismos de atención y arquitecturas bidireccionales refuerzan la capacidad de los modelos para representar patrones temporales no lineales, componentes estacionales y variaciones bruscas en los precios agrícolas. A ello se le suman los resultados de (Ryu et al., 2023), quienes proponen una arquitectura orientada a eventos críticos dispersos, demostrando que la identificación y retención de sucesos relevantes puede mejorar el comportamiento predictivo en series agrícolas. Estos aportes reflejan que el aprendizaje profundo ha avanzado hacia modelos más especializados para abordar la complejidad de los mercados agroalimentarios.

Sin embargo, aunque los modelos de aprendizaje profundo han mostrado resultados favorables, diversos estudios señalan la importancia de realizar comparaciones sistemáticas entre enfoques estadísticos, aprendizaje automático y aprendizaje profundo. Esto se debe a que el desempeño de cada modelo depende de las características particulares de la serie, la disponibilidad de datos, la presencia de variables exógenas y el horizonte de pronóstico. En este sentido, estudios como los de (Nassar et al., 2020) y (Nayak et al., 2024) evidencian que los modelos avanzados tienden a superar a los enfoques tradicionales en determinados escenarios, especialmente cuando integran información adicional al comportamiento histórico de los precios. No obstante, esta superioridad no debe asumirse de manera general, sino verificarse mediante métricas de error y evaluaciones comparativas.

La incorporación de variables exógenas en los modelos predictivos es otro aspecto relevante encontrado en la literatura. Estudios como el de (Nayak et al., 2024) muestran que factores externos pueden complementar la información de la serie histórica, aportando a la capacidad del modelo para representar la dinámica del mercado. De forma similar, (Min et al., 2025) reportan resultados favorables con enfoques multivariados que consideran fluctuaciones de corto plazo y variables del entorno, mientras que (Gu et al., 2022) evidencian la utilidad de mecanismos de atención para identificar características relevantes dentro de conjuntos de datos multivariados. En conjunto, estos estudios respaldan la pertinencia de incluir variables externas en

la predicción de precios agrícolas, aunque su contribución real depende del producto, las variables disponibles y el enfoque de modelado utilizado.

Desde una perspectiva aplicada, la predicción de precios agrícolas también posee utilidad práctica para los actores de la cadena agroalimentaria. Estudios como los de (Jaiswal et al., 2023) y (Vairo et al., 2024) señalan que una mayor capacidad para anticipar el comportamiento de los precios puede apoyar decisiones relacionadas con comercialización, abastecimiento, inventarios y planificación productiva. En este sentido, los modelos predictivos no solo tienen valor técnico, sino también potencial como herramientas de apoyo para la toma de decisiones en contextos de incertidumbre.

Dentro de este marco, los mercados mayoristas del Ecuador constituyen un escenario pertinente para la aplicación y comparación de modelos predictivos, debido a su relevancia dentro de la comercialización agrícola y a la disponibilidad de información histórica comparable. Mercados como el Mercado Mayorista de Quito, la Terminal de Transferencia de Víveres de Guayaquil y el Mercado Mayorista Terminal El Arenal de Cuenca representan espacios relevantes dentro de la dinámica de abastecimiento y formación de precios mayoristas del país (MAG, 2019).

Para sintetizar los principales antecedentes revisados y facilitar su comparación, en la **Tabla 1** se presentan los enfoques metodológicos y los aportes más relevantes de los estudios relacionados con la predicción de precios agrícolas. Esta síntesis permite identificar la evolución desde modelos basados en el comportamiento histórico de las series hacia enfoques capaces de incorporar relaciones no lineales, dependencias temporales y variables externas.

Tabla 1

Síntesis comparativa de estudios relacionados con la predicción de precios agrícolas

Autor(es)	Enfoque/modelo	Aporte al presente estudio
(Yin et al., 2020)	Modelos de aprendizaje profundo	Evidencia la complejidad no lineal y no estacionaria de los precios agrícolas.

Autor(es)	Enfoque/modelo	Aporte al presente estudio
(F. Wang et al., 2021)	Redes recurrentes/LSTM	Respaldan el uso de modelos recurrentes para representar dependencias temporales.
(Gu et al., 2022)	LSTM con mecanismos de atención	Muestran la utilidad de incorporar información adicional y relaciones temporales en modelos multivariados de precios agrícolas.
(Noboa et al., 2022)	Aprendizaje profundo	Antecedente nacional de aplicación de aprendizaje profundo para el pronóstico de precios agrícolas.
(Ryu et al., 2023)	Aprendizaje profundo orientado a eventos	Evidencian la importancia de representar cambios y eventos relevantes dentro de series agrícolas variables.
(Guindani et al., 2024)	Revisión de métodos de pronóstico	Identifican la coexistencia de enfoques estadísticos y de inteligencia artificial para la predicción de productos agrícolas.
(Nayak et al., 2024)	Aprendizaje profundo multivariado	Respaldan la incorporación de factores externos para complementar la información histórica de los precios.
(Theofilou et al., 2025)	Comparación de métodos predictivos	Evidencian la utilización conjunta de métodos estadísticos, aprendizaje automático y aprendizaje profundo en problemas de pronóstico agrícola

La revisión de antecedentes muestra que no existe un único enfoque predictivo que pueda ser considerado superior para todos los escenarios agrícolas de manera general. El desempeño depende de las características de las series, la disponibilidad de información, las variables incorporadas y la estrategia de evaluación utilizada. De igual forma, los antecedentes muestran un creciente interés por los enfoques multivariados y por la incorporación de factores externos al historial del precio, aunque sus beneficios deben comprobarse experimentalmente para cada contexto de aplicación.

En el caso ecuatoriano, la evidencia disponible continúa siendo limitada en comparación con la producción internacional. Aunque existen antecedentes como el estudio de (Noboa et al., 2022), donde se aplica aprendizaje profundo para el pronóstico de precios en el mercado mayorista de Ibarra, persiste un vacío metodológico significativo y se presenta la oportunidad de comparar bajo un mismo diseño experimental modelos estadísticos, de aprendizaje automático y de aprendizaje profundo, así como evaluar específicamente el aporte de variables económicas y sectoriales. Este vacío sustenta la pertinencia del presente estudio aplicado a precios mayoristas de productos agrícolas en Ecuador.

Marco Teórico

Mercado agrícola y comportamiento de precios

Los mercados agrícolas se diferencian de otros mercados de bienes debido a la dependencia de la producción respecto de factores biológicos, climáticos, estacionales, logísticos y económicos. La formación de precios en este tipo de mercados no depende únicamente a la relación inmediata entre oferta y demanda, sino también a condiciones estructurales como la disponibilidad del producto, los ciclos de cosecha, los costos de producción, el almacenamiento, la perecibilidad y la distribución territorial de los bienes agrícolas. La volatilidad de los precios es una característica frecuente de estos mercados, y pueden originarse por cambios en la producción, demanda, disponibilidad de inventarios, condiciones climáticas, precios de insumos, costos logísticos y vínculos con otros mercados. Por tal motivo, (OECD/FAO, 2024) indica que las proyecciones de los mercados agrícolas deben considerar factores macroeconómicos, productividad, clima, consumo, comercio y políticas agrícolas, debido a su influencia sobre la evolución del sector.

La estacionalidad y la perecibilidad son reconocidos por (Pan & Zheng, 2023) como elementos relevantes en el comportamiento de los precios agrícolas. Dado que numerosos productos se cultivan y comercializan de acuerdo con ciclos determinados, su disponibilidad varía

entre periodos, originando variaciones recurrentes en los precios. En los productos perecibles, dichas variaciones resultan más pronunciadas, debido a que las restricciones de almacenamiento y conservación limitan la posibilidad de retener inventarios por tiempos prolongados. El estudio de (Pan & Zheng, 2023) evidencia que, para productos perecibles, la volatilidad de los precios puede transferirse entre las etapas de productor, mayorista y minorista, demostrando que el comportamiento del precio forma parte de una cadena comercial dinámica e interrelacionada.

Además, los precios agrícolas pueden variar entre mercados y territorios, debido a distintos factores como: costos de transporte, intermediarios, distancia entre zonas productores y centros de consumo, infraestructura vial, etc. (Lambert et al., 2025) afirma que comprender y mitigar la volatilidad espacial y temporal de los precios agrícolas representa un desafío relevante, especialmente porque las variaciones de los precios pueden incidir en la seguridad alimentaria y en los ingresos de los agricultores. En este sentido, el estudio de los precios en mercados mayoristas resulta pertinente, ya que es en estos mercados donde se concentra la información sobre la circulación de productos agrícolas y permiten observar tendencias en puntos estratégicos de comercialización.

Es importante aclarar que el comportamiento de los precios agrícolas no siempre se comporta de manera proporcional o inmediata a los cambios ocurridos en otros niveles de la cadena agroalimentaria. Por ello (Harshana & Ratnasiri, 2023) identifican que la transmisión de precios entre niveles mayoristas y minoristas en frutas y vegetales puede ser asimétrico en magnitud y velocidad, lo cual evidencia que los ajustes de precios dependen de la estructura del mercado y de las relaciones entre sus actores. Esta característica resulta relevante, ya que permite entender que el precio registrado en los mercados mayoristas responde tanto a condiciones productivas como a dinámicas comerciales propias de la cadena de abastecimiento.

En este contexto, el comportamiento de los precios agrícolas es temporal, variable y multicausal, con patrones estacionales, diferencias territoriales y posibles vínculos con factores

externos. (Das et al., 2026) analizan la incorporación de variables meteorológicas en problemas de predicción agrícola, mostrando el creciente interés de los investigadores por considerar información adicional al historial del precio. Estos antecedentes justifican la pertinencia de examinar el aporte de variables externas en el modelado predictivo, sin asumir que su inclusión garantice una mejora automática.

Series temporales y predicción de precios agrícolas

Una serie temporal es definida como un conjunto de observaciones ordenadas de forma cronológica, en las que cada valor es registrado en un momento específico y mantiene una relación con los valores anteriores. En el análisis de precios agrícolas, el uso de series temporal resulta adecuado ya que los precios no se comportan como datos aislados, sino como registros sucesivos que pueden reflejar tendencias, patrones estacionales, ciclos y fluctuaciones aleatorias. En consecuencia, el estudio de series temporales permite examinar la evolución histórica de los precios y generar estimaciones sobre su comportamiento futuro.

En el contexto agrícola, la predicción de precios mediante el uso de series temporales se ha establecido como una herramienta importante para respaldar la toma de decisiones de productores, comerciantes, consumidores e instituciones públicas. De acuerdo con (F. Sun et al., 2023), la estimación de precios de productos agrícolas representa un tema de investigación relevante, dado que una proyección más precisa puede favorecer el desarrollo saludable y sostenible del sector agrícola. Esta relevancia se relaciona con la necesidad de anticipar variaciones de precios que puedan afectar la planificación de la producción, las actividades de comercialización y la gestión de riesgos.

El análisis de series temporales permite identificar componentes relevantes del comportamiento de los precios, como: la tendencia, la estacionalidad y la variabilidad irregular. La tendencia representa la dirección general de la serie a largo plazo; la estacionalidad se refiere a patrones que se repiten en determinados periodos; y las variaciones irregulares representan

cambios no sistemáticos asociados con eventos externos o perturbaciones del mercado (Hyndman & Athanasopoulos, 2021e). Dichos componentes pueden presentar con mayor intensidad en productos agrícolas debido a los ciclos de producción, la disponibilidad del producto, las condiciones climáticas y las dinámicas de comercialización.

Estudios recientes evidencian que la predicción de precios agrícolas ha evolucionado desde enfoques estadísticos tradicionales hacia métodos de aprendizaje automático, aprendizaje profundo y modelos híbridos. (Guindani et al., 2024) muestran que las metodologías de pronóstico de series temporales en el ámbito económico agrícola abarcan una variedad de enfoques, como modelos estadísticos, técnicas computacionales y estrategias combinadas. Igualmente, (Theofilou et al., 2025) destacan en su estudio como la incorporación de técnicas de aprendizaje automático, aprendizaje profundo y modelos de series temporales mejoran la precisión de las estimaciones de precios agrícolas.

Los modelos de predicción también pueden diferenciarse según la información empleada. Las configuraciones de una variable utilizan únicamente los valores históricos del precio para generar estimaciones, mientras que los enfoques multivariados incluyen información adicional que puede estar relacionada con su comportamiento. (Nayak et al., 2024), por ejemplo, analizan la inclusión de variables externas como precipitación y temperatura en la predicción de precios agrícolas, lo que refleja el interés por determinar si la información complementaria mejora el rendimiento predictivo en comparación con el uso exclusivo del historial de precios.

El horizonte de pronóstico define el número de periodos futuros que se pretende estimar y es importante para interpretar el desempeño de los modelos. Mientras aumenta la distancia desde el último valor observado, la predicción se vuelve más incierta, al disponer de menos información empírica sobre la evolución futura de la serie y sus factores asociados. Para este estudio se consideran horizontes de corto plazo de uno a tres meses, permitiendo evaluar cómo cambia el rendimiento de los modelos a medida que se extiende el periodo de estimación.

Modelos estadísticos para pronóstico

Los modelos estadísticos de series temporales se consideran un enfoque clásico para el análisis y predicción de datos ordenados cronológicamente, al representar relaciones entre las observaciones actuales y su comportamiento histórico. Dentro de esta familia, ARIMA integra componentes autorregresivos, de diferenciación y de media móvil para modelar la dependencia temporal de una serie. (Hyndman & Athanasopoulos, 2021a) afirman que los modelos ARIMA permiten capturar las autocorrelaciones presentes en los datos y constituyen una referencia ampliamente utilizada en problemas de pronóstico.

A partir de la estructura de ARIMA se han desarrollado extensiones que permiten representar características adicionales de las series temporales. SARIMA incorpora componentes estacionales para modelar patrones que se repiten con una periodicidad determinada, como puede ocurrir en los precios agrícolas debido a ciclos productivos y comerciales. Por su parte, SARIMAX amplía esta estructura al permitir incorporar variables exógenas junto con la dinámica histórica y estacional de la variable objetivo. De acuerdo con (Alharbi & Csala, 2022), este enfoque permite combinar información temporal con factores externos que pueden contribuir a explicar el comportamiento de la serie.

En la predicción de precios agrícolas, los modelos de esta familia constituyen una referencia metodológica útil para contrastar enfoques de mayor complejidad. (Paul et al., 2025), por ejemplo, incluyen ARIMA como modelo de referencia al comparar métodos tradicionales con arquitecturas de aprendizaje profundo aplicadas a precios mayoristas agrícolas. No obstante, las series agrícolas pueden presentar volatilidad, relaciones no lineales y sensibilidad a factores externos asociados con la oferta, demanda, producción o condiciones del mercado (Ray et al., 2023), lo que puede limitar el desempeño de modelos sustentados en relaciones temporales lineales. Por esta razón, estudios como el de (Krishna et al., 2026) comparan o combinan estos

modelos con técnicas de aprendizaje automático y aprendizaje profundo para representar estructuras más complejas de los datos.

En este contexto, el presente estudio se adopta SARIMAX como representante del enfoque estadístico, debido a que permite modelar componentes temporales, estacionales y evaluar el efecto de incorporar variables exógenas. Esta flexibilidad permite evaluar el modelo tomando en cuenta únicamente el historial del precio, o incluyendo factores económicos y sectoriales. De esta forma, es posible analizar de manera controlado el aporte de la información externa y comparar su desempeño con los enfoques de aprendizaje automático y aprendizaje profundo.

Modelos de aprendizaje automático aplicados a la predicción

El aprendizaje automático es una rama de la inteligencia artificial enfocada en desarrollar algoritmos con la capacidad de identificar patrones en los datos y así generar predicciones. Estos algoritmos procesan datos históricos para aprender relaciones relevantes y aplicarlas en tareas de clasificación, regresión o pronóstico (Sarker, 2021). Los modelos estadísticos tradicionales suelen basarse en supuestos específicos sobre la estructura de la serie temporal, por el contrario, los modelos de aprendizaje automático pueden adaptarse a relaciones complejas, no lineales y multivariadas. Esta característica resulta valiosa en el análisis de precios agrícolas, ya que estos pueden estar afectados por múltiples factores económicos, productivos, climáticos y comerciales.

En este contexto, los modelos de aprendizaje automática son relevantes por su capacidad para incorporar variables explicativas adicionales, transformar datos históricos en características predictivas y capturar relaciones que no siempre son evidentes mediante modelos lineales. Entre los modelos de aprendizaje automático utilizados en el ámbito de la predicción destacan: árboles de decisión, Random Forest, Support Vector Regression (SVR), Gradient Boosting y XGBoost. Estos modelos son capaces de resolver problemas de regresión, donde el objetivo es estimar un valor continuo, como el precio futuro de un producto agrícola (Murugesan et al., 2022).

El boosting es una técnica de aprendizaje ensamblado en la que varios modelos se construyen de manera secuencial, y cada nuevo componente busca corregir los errores o residuos de los anteriores. Una variante de esta técnica es Gradient Boosting, que optimiza progresivamente una función de pérdida añadiendo sucesivamente modelos, generalmente árboles de decisión. XGBoost extiende este enfoque con regularización y optimización computacional (Chen & Guestrin, 2016), permitiendo representar relaciones no lineales e interacciones multivariadas sin especificación funcional previa. En predicción agrícola, esta flexibilidad es valioso cuando el precio responde a información histórica, características temporales y factores económicos. A diferencia de modelos estadísticos, XGBoost aborda el problema como regresión supervisada, por lo que la temporalidad debe incorporarse mediante características derivadas de los datos.

Estudios recientes, como el de (Ogol et al., 2025), muestran que los modelos de aprendizaje automático pueden lograr un desempeño competitivo en la predicción de precios agrícolas, al considerar información como precios históricos, tipo de cambio e inflación, incluyendo métodos basados en gradient boosting. De manera similar, (Cheng & Li, 2025) propusieron un modelo combinado entre Lasso y XGBoost para pronosticar el precio del maíz, evidenciando el interés por integrar técnicas de aprendizaje automático con conjuntos de variables de diferente naturaleza.

Sin embargo, aunque los modelos de aprendizaje automático presentan ventajas significativas, también presentan desafíos metodológicos, ya que su rendimiento depende de factores como: calidad de datos, selección de variables, manejo de valores ausentes, creación de características temporales, una adecuada partición entre conjuntos de entrenamiento y prueba, y el ajuste de hiper parámetros. (Brignoli et al., 2024), en su estudio, señalan que los métodos de machine learning tienen potencial para mejorar la precisión de los pronósticos agrícolas, pero requieren un adecuado preprocesamiento de los datos y una cuidadosa configuración metodológica para evitar resultados poco generalizables.

En el presente estudio, XGBoost representa el enfoque de aprendizaje automático y se utiliza para analizar el comportamiento predictivo a partir de características temporales, el histórico del precio y, según la configuración evaluada, variables exógenas económicas y sectoriales. Su desempeño se contrasta con la configuración que omite estas variables, así como con los otros enfoques incluidos en la investigación.

Redes neuronales recurrentes y modelos de aprendizaje profundo

Las redes neuronales recurrentes constituyen una arquitectura de aprendizaje profundo diseñada específicamente para procesar datos secuenciales, donde el orden de las observaciones resulta relevante para comprender el comportamiento de la variable estudiada. A diferencia de las redes neuronales tradicionales que tratan cada entrada de manera independiente, las redes neuronales recurrentes incorporan conexiones internas que les permiten retener información de estados previos y utilizarla en el procesamiento de nuevas observaciones. Esta característica las vuelve apropiadas para problemas relacionados con series temporales, procesamiento del lenguaje natural, señales y otros tipos de datos que dependen del tiempo (Goodfellow et al., 2017).

Las redes neuronales recurrentes tradicionales presentan limitaciones al momento de aprender dependencias de largo plazo, debido a problemas como el desvanecimiento o el crecimiento desmedido del gradiente durante el entrenamiento. Estos problemas impiden que la red retenga información relevante de pasos temporales distantes dentro de una secuencia. Ante estas limitaciones, (Hochreiter & Schmidhuber, 1997) propusieron la arquitectura Long Short-Term Memory LSTM, que incorpora mecanismos internos de memoria y compuertas encargadas de regular qué información se conserva, actualiza o descarta a lo largo de una secuencia. Esta estructura permite mantener información relevante durante diferentes intervalos temporales y representar relaciones secuenciales complejas.

En el análisis de precios agrícolas, LSTM resulta apropiado debido a que las series pueden presentar dependencias temporales, estacionalidad, cambios no lineales y variaciones asociadas

con diferentes factores del mercado. (Zhang & Tang, 2024) analizan la capacidad de esta arquitectura para representar patrones no lineales en series temporales, mientras que (Theofilou et al., 2025) y (Xia, 2024) destacan a LSTM entre los métodos de aprendizaje profundo empleados en la predicción de precios agrícolas, junto con técnicas estadísticas y de aprendizaje automático. Estos antecedentes confirman su aplicabilidad en contextos de pronóstico, aunque su desempeño depende de las características de los datos, la configuración de la red y el procedimiento de entrenamiento y validación.

Para aplicar LSTM, los datos deben organizarse en secuencias temporales formadas por observaciones de periodos anteriores. La longitud de la secuencia, también conocida como ventana temporal, determina cuántos meses previos utiliza el modelo para realizar una predicción. (Gu et al., 2022) emplean una arquitectura LSTM en la predicción de precios agrícolas, con el fin de representar relaciones temporales entre información histórico y variables externas. Además de la longitud de la venta, el número de unidades LSTM es un parámetro relevante de la arquitectura, porque influye en la capacidad del modelo para aprender patrones presentes en las secuencias. Por esta razón, ambos parámetros pueden evaluarse durante el proceso de validación antes de definir la configuración final del modelo.

En el presente estudio, LSTM representa el enfoque de aprendizaje profundo y se utiliza para modelar secuencias mensuales por provincia. Al igual que los demás enfoques, se evalúa mediante configuraciones con y sin variables exógenas económicas y sectoriales, lo que permite estudiar su comportamiento a partir del historial del precio y analizar el aporte de la información adicional.

Variables exógenas en la predicción de precios agrícolas

Las variables exógenas representan factores externos a la variable objetivo que pueden incluirse a un modelo con el propósito de aportar información adicional sobre el fenómeno analizado (Y. Wang et al., 2024). En la predicción de precios agrícolas, la variable objetivo

usualmente es el precio futuro del producto, mientras que las variables exógenas pueden estar relacionadas con factores económicos, productivos y sectoriales relacionados con la dinámica del mercado. Su inclusión permite desarrollar enfoques multivariados en los que el pronóstico no depende únicamente de los valores anteriores de la serie.

La utilización de estas variables se debe a que los precios agrícolas pueden estar relacionados con factores de oferta y demanda, producción, estacionalidad, clima, transporte, costos de insumos, inflación y otros aspectos económicos (Nguyen et al., 2024). Desde una perspectiva económica, la (OECD/FAO, 2024) señala que la evolución de los mercados agrícolas está vinculada con factores macroeconómicos, condiciones productivas, costos de insumos, comercio y políticas agrícolas. Es así como, variables como el precio productor, los fertilizantes, el IPC de alimentos, la inflación y los índices sectoriales pueden ser fuentes complementarias de información para el modelado predictivo.

Estudios recientes, como el de (Nayak et al., 2024), incorporan variables climáticas, como precipitación y temperatura, en modelos de aprendizaje profundo para el pronóstico de precios de tomate, cebolla y papa en India, evidenciando mejoras frente a configuraciones basadas únicamente en el historial del precio. De forma similar, (Gu et al., 2022) desarrollan un modelo basado en LSTM con un mecanismo de atención dual que integra información meteorológica y volumen de comercio, con el fin de representar relaciones temporales y asociaciones entre variables relacionadas con el comportamiento del mercado.

Sin embargo, la incorporación de información externa no garantiza por sí misma un mejor desempeño predictivo. Su utilidad depende de varios factores, como la relación de las variables con el fenómeno analizado, su cobertura temporal y territorial, la frecuencia de los datos y el tratamiento aplicado durante su integración. También influyen aspectos metodológicos como los valores ausentes, los rezagos temporales, la normalización y la disponibilidad de las variables al momento de generar nuevos pronósticos. (Nayak et al., 2024) advierten que una selección o

tratamiento inadecuado de variables externas puede introducir ruido y limitar la capacidad de generalización del modelo.

En este estudio se consideran como variables externas el precio productor, los precios de fertilizantes, el IPC, la inflación y los índices sectoriales. Se aporte se evalúa mediante configuraciones comparables dentro de SARIMAX, XGBoost y LSTM, de modo que cada modelo se analice con y sin dicha información adicional. De esta forma se puede determinar experimentalmente si estas variables aportan al desempeño predictivo, sin asumir de antemano un efecto favorable.

Evaluación del desempeño de modelos predictivos

La evaluación del desempeño de los modelos predictivos es una etapa fundamental en los estudios de pronóstico, ya que permite determinar la precisión de las estimaciones y valorar su capacidad para generalizar frente a datos no utilizadas durante el entrenamiento. En problemas de series temporales, esta evaluación debe preservar el orden cronológico de los datos, porque una partición aleatoria puede incorporar información futura en etapas anteriores del proceso y producir estimaciones poco representativas del comportamiento real del modelo. En este sentido, la evaluación sobre periodos posteriores al entrenamiento permite aproximarse mejor a un escenario de pronóstico real (Cerqueira et al., 2020; Hyndman & Athanasopoulos, 2021c).

Para diferenciar el ajuste del modelo de su evaluación final, los datos pueden organizarse en conjuntos de entrenamiento, validación y prueba. El conjunto de entrenamiento se utiliza para ajustar los parámetros del modelo, mientras que la validación permite seleccionar configuraciones o hiperparámetros sin utilizar el conjunto de prueba. Este debe mantenerse separado hasta la evaluación final, para obtener una estimación independiente del desempeño predictivo. En series temporales, la validación puede realizarse mediante diferentes cortes cronológicos, de esta forma el modelo se entrena con información previa y se evalúa sobre periodos posteriores (Cerqueira et al., 2020).

La utilización de múltiples periodos de validación es útil cuando las series presentan cambios a lo largo del tiempo, debido a que el rendimiento observado en un único intervalo puede no representar el comportamiento del modelo en otros periodos. De esta manera, la validación temporal ofrece una base más estable para la selección del modelo, mientras que el conjunto de prueba se reserva para reportar su desempeño final.

La comparación entre modelos requiere también métricas que permitan analizar diferentes dimensiones del error predictivo. Ningún indicador proporciona por sí solo una caracterización completa del rendimiento, por lo que conviene considerar conjuntamente medidas de error absoluto, error relativo, ajuste general y capacidad para anticipar la dirección de los cambios (Hyndman & Athanasopoulos, 2021b).

El error absoluto medio, MAE, representa el promedio de las diferencias absolutas entre los valores observados y los pronosticados. La utilidad de esta métrica radica en que mantiene la misma unidad de medida que la variable de interés, facilitando la interpretación dentro del contexto del estudio. (Yahaya Shehu et al., 2024), un estudio enfocado a precios agrícolas, señalan que el MAE permite conocer la magnitud del error de predicción en la misma escala de los precios, lo que la convierte en una métrica directa y comprensible para evaluar el desempeño del modelo.

La raíz del error cuadrático medio, RMSE, cuantifica la diferencia entre los valores observados y los estimados, asignando un peso mayor a los errores de mayor magnitud al elevarlos al cuadrado antes de promediarlos. Esta característica vuelve al RMSE útil cuando se busca penalizar desviaciones grandes o errores extremos en el pronóstico. (Hyndman & Koehler, 2006) señalan que, debido a su sensibilidad a errores atípicos, debe analizarse de manera complementaria con otras métricas como el MAE y el MAPE.

El error porcentual absoluto medio, MAPE, expresa el error de predicción en términos porcentuales con respecto al valor real observado. Su principal ventaja es que ofrece una medida

relativa del rendimiento, facilitando la comparación entre series que presentan distintos niveles de precios (Hyndman & Koehler, 2006). Sin embargo, (Makridakis et al., 2022) advierten que su interpretación debe hacerse con cuidado cuando los valores reales son iguales o muy cercanos a cero, debido a que en esos casos el cálculo porcentual puede producir distorsiones. Por esta razón, el MAPE debe utilizarse teniendo en cuenta las características de la variable objetivo y la distribución de los datos.

El coeficiente de determinación, R^2 , permite evaluar qué proporción de la variabilidad de la variable objetivo explica el modelo, donde los valores cercanos a uno indican un mayor ajuste entre los valores observados y predichos, mientras que valores bajos o negativos pueden reflejar un desempeño deficiente. (Chicco et al., 2021) advierten que, en problemas de predicción, el R^2 debe interpretarse como una medida complementaria, ya que un buen ajuste global no implica necesariamente un error de pronóstico reducido.

La precisión direccional, Directional Accuracy, calcula el porcentaje de aciertos del modelo al predecir si la variable aumenta o disminuye respecto de un periodo anterior. (Cao & Tay, 2003) señalan que, en el contexto de precios agrícolas, esta métrica resulta relevante porque importa estimar la magnitud del precio futuro, y también anticipar si este tenderá a subir o bajar. Así, la evaluación direccional complementa a las métricas de error tradicionales al analizar la capacidad del modelo para identificar el sentido del movimiento del precio.

El número de observaciones empleadas en el conjunto de prueba, n_{test} , permite contextualizar las métricas obtenidas. Los indicadores calculados sobre muestras pequeñas pueden ser sensibles a observaciones individuales, mientras que diferencias en el tamaño o composición de los conjuntos evaluados pueden afectar la compatibilidad entre modelos. Por eso, al hacer comparaciones directas es conveniente usar observaciones equivalentes y tener en cuenta el tamaño de la muestra sobre la que se calcularon las métricas (Arlot & Celisse, 2010).

En conjunto, estas métricas permiten evaluar el desempeño predictivo desde perspectivas complementarias: unas miden la magnitud del error, otras lo expresan en términos relativos, evalúan el ajuste global del modelo y otras identifican su capacidad para anticipar la dirección del cambio. En la **Tabla 2** se presentan de manera sintética las métricas consideradas en esta investigación y, en la **Tabla 3**, los criterios de interpretación asociados, con el objetivo de contar con una base común que permita comparar posteriormente los modelos predictivos.

Tabla 2

Métricas de evaluación de modelos predictivos

Métrica	Unidad o escala	Interpretación teórica
MAE	Misma unidad que la variable objetivo	Promedio de las diferencias absolutas entre valores reales y predichos
RMSE	Misma unidad que la variable objetivo	Penaliza con mayor intensidad los errores de gran magnitud.
MAPE	Porcentaje	Error promedio en términos relativos respecto del valor real observado.
R ²	Escala relativa	Proporción de variabilidad de la variable objetivo.
Directional Accuracy	Porcentaje	Proporción de aciertos al predecir la dirección del cambio respecto al periodo anterior.
n _{test}	Conteo	Cantidad de observaciones usadas para calcular las métricas de evaluación.

Tabla 3

Criterios de evaluación del desempeño predictivo

Criterios de evaluación	Métricas asociadas	Pregunta que permite responder
Magnitud del error	MAE, RMSE	¿Qué tan alejadas están las predicciones de los valores reales?

Criterios de evaluación	Métricas asociadas	Pregunta que permite responder
Error relativo	MAPE	¿Qué porcentaje del valor real representa el error promedio?
Ajuste general	R^2	¿Qué proporción de la variabilidad del precio explica el modelo?
Dirección del cambio	Directional Accuracy	¿El modelo acierta si el precio sube o baja respecto al periodo anterior?
Tamaño de evaluación	n_{test}	¿Con cuántas observaciones se evaluó el modelo?

Visualización de resultados predictivos

La visualización de resultados es un componente relevante en los sistemas de análisis predictivo ya que permite representar información compleja de forma gráfica y facilita su interpretación. En problemas de series temporales, herramientas como gráficos históricos, proyecciones y métricas de desempeño ayudan a identificar tendencias, comparar valores observados y estimados, y comunicar los resultados a usuarios con distintos niveles de conocimiento técnico. (Htun et al., 2022) señalan que la visualización puede contribuir a transformar resultados analíticos en información comprensible.

En el ámbito agrícola, las herramientas de visualización pueden integrar la evolución histórica de los precios, los pronósticos generados y los indicadores de rendimiento de los modelos. (Ooge & Verbert, 2022) señalan que los sistemas de apoyo visual en el sector agroalimentario pueden incluir pronóstico de precios, representación de incertidumbre y analítica visual para facilitar la interpretación de la información. Así, tableros o prototipos web pueden organizar la información mediante gráficos de series temporales, comparaciones entre modelos, filtros por producto o mercado y resúmenes de indicadores, facilitando la consulta y comparación de las estimaciones generadas.

En el presente estudio, la visualización se implementa mediante un prototipo web funcional orientado a la consulta de pronósticos por producto, provincia y horizonte temporal. Su propósito es presentar de forma accesible el comportamiento histórico y los resultados generados por los modelos, sin constituir una plataforma transaccional ni un sistema integral de gestión comercial. Los pronósticos presentados corresponden a estimaciones puntuales, por lo que su interpretación debe realizarse considerando las limitaciones metodológicas del estudio y la ausencia de intervalos predictivos.

Terminología

En la **Tabla 4** se presentan las principales definiciones operativas relacionadas con el análisis de precios agrícolas, series temporales, modelos predictivos, variables exógenas, métricas de evaluación y visualización de resultados. Estas definiciones permiten delimitar el sentido en que cada término será utilizado dentro del presente estudio.

Tabla 4

Definiciones operativas relacionadas con el estudio

Término	Definición operativa en el estudio
Aprendizaje automático	Enfoque de inteligencia artificial que aprende patrones a partir de datos.
Aprendizaje profundo	Subcampo del aprendizaje automático basado en redes neuronales con múltiples capas.
ARIMA	Modelo estadístico de series temporales basado en componentes autorregresivos, diferenciación y media móvil.
SARIMA	Extensión de ARIMA que incorpora componentes estacionales para representar patrones periódicos de una serie temporal.
SARIMAX	Extensión de SARIMA que permite incorporar variables exógenas como información adicional para el modelado y pronóstico.
Block bootstrap	Técnica de muestreo que conserva grupos consecutivos de observaciones para considerar la dependencia temporal durante la estimación de incertidumbre.

Término	Definición operativa en el estudio
Boosting	Técnica de aprendizaje ensamblado que combina modelos débiles de forma secuencial para mejorar el desempeño predictivo.
Carry-forward	Estrategia que mantiene el último valor conocido de una variable para periodos futuros cuando su valor real aún no se encuentra disponible.
Conjunto de entrenamiento	Subconjunto de datos utilizado para ajustar o entrenar el modelo predictivo.
Conjunto de prueba	Subconjunto de datos no utilizado durante el entrenamiento, utilizado para evaluar el desempeño del modelo frente a observaciones nuevas.
Directional Accuracy	Métrica que mide el porcentaje de veces que el modelo acierta la dirección del cambio de la variable.
Estacionalidad	Patrón que se repite en intervalos regulares dentro de una serie temporal.
Gradient Boosting	Método de <i>boosting</i> que construye modelos sucesivos mediante la optimización de una función de pérdida.
LSTM	Modelo de red neuronal recurrente diseñado para aprender dependencias temporales de largo.
Machine Learning	Enfoque de inteligencia artificial que permite a los algoritmos aprender patrones a partir de datos y generar predicciones.
MAE	Error absoluto medio, métrica que calcula el promedio de errores absolutos entre valores reales y predichos.
MAPE	Error porcentual absoluto medio, métrica que expresa el error de predicción en porcentaje respecto al valor real.
Mercado mayorista	Espacio donde se concentran y comercializan productos agrícolas, generando precios de referencia.
Modelo de una variable	Modelo que utiliza únicamente la información histórica de la variable objetivo para generar predicciones.
Modelo multivariado	Modelo que incorpora la variable objetivo junto con otras variables explicativas o exógenas.
Modelo predictivo	Técnica utilizada para estimar valores futuros de una variable objetivo.
N_{test}	Número de observaciones utilizadas en el conjunto de prueba.

Término	Definición operativa en el estudio
Precio agrícola	Valor monetario de un producto agrícola en un mercado y periodo determinado.
Precio mayorista	Precio registrado en mercados mayoristas para productos comercializados en volúmenes significativos.
Precio productor	Valor recibido por el productor por la venta de un producto agrícola.
Predicción	Estimación de valores futuros a partir de datos históricos y variables relacionadas.
Producto agrícola	Bien proveniente de la actividad agrícola y sujeto a comercialización.
Pronóstico	Resultado generado por un modelo para anticipar el comportamiento futuro de una variable.
Prototipo web	Interfaz para consulta y visualización de resultados del modelo.
R^2	Métrica que indica la proporción de variabilidad explicada por el modelo.
Random Forest	Algoritmo de aprendizaje automático que combina múltiples árboles de decisión.
Red neuronal recurrente	Red neuronal diseñada para procesar datos secuenciales.
RMSE	Métrica que mide el error cuadrático medio y penaliza errores grandes.
Serie temporal	Conjunto de observaciones ordenadas cronológicamente.
Sobreajuste	Situación en la que el modelo pierde capacidad de generalización por ajustarse demasiado al entrenamiento.
Tendencia	Dirección general que sigue una serie temporal en el tiempo.
Variable exógena	Factor externo que aporta información adicional para explicar o predecir la variable objetivo.
Variable objetivo	Variable que se desea predecir mediante el modelo, en este contexto, el precio de los productos.
Visualización de datos	Representación gráfica de información para facilitar su análisis e interpretación.
XGBoost	Algoritmo de boosting que construye modelos secuenciales para reducir errores de predicción.

Capítulo 3. Desarrollo

Desarrollo del Trabajo

El desarrollo de este estudio fue con el propósito de comparar el desempeño de distintos modelos de predicción para estimar precios de productos agrícolas en Ecuador. Para cumplir este objetivo se siguió un proceso secuencial que comprende la recopilación e integración de datos, su preparación y transformación, la construcción de variables, el entrenamiento y validación de los modelos, la evaluación comparativa de resultados y la implementación de un prototipo web. Todo este proceso se diseñó considerando la naturaleza temporal de los precios agrícolas y la necesidad de preservar el orden cronológico de los datos en cada etapa del modelado.

El estudio se aplicó en tres productos agrícolas: Papa Superchola, Tomate Riñón de Invernadero y Maracuyá, utilizando información proveniente principalmente del Sistema de Información Pública Agropecuaria (SIPA, 2026a). Los datos fueron integrados en conjuntos con frecuencia mensual, donde la unidad de observación es la combinación producto-provincia-mes. A partir de esta estructura, se relacionaron los precios mayoristas con el historial de precios, variables temporales y variables exógenas económicas y sectoriales.

La comparación de modelos se realizó considerando tres enfoques: SARIMAX como modelo estadístico de series temporales, XGBoost como modelo de aprendizaje automático y LSTM como modelo de aprendizaje profundo. Cada familia de modelos fue evaluada mediante una configuración base y otra complementada con variables exógenas, permitiendo analizar de forma controlada el aporte de esta información sin confundir su efecto con las diferencias propias de cada algoritmo.

La evaluación se organizó mediante una separación cronológica entre desarrollo y prueba, integrando ventanas de validación temporal dentro del conjunto de desarrollo para la sección de configuraciones y parámetros. El conjunto de prueba se mantuvo independiente de este proceso y fue reservado para la evaluación final. Además, la comparación de los modelos consideró métricas

predictivas, procedimientos estadísticos para analizar las diferencias observadas y su comportamiento en horizontes de pronóstico de uno a tres meses.

El desarrollo de un prototipo web permite consultar pronósticos por producto, provincia y horizonte temporal. La selección del modelo final para cada producto se realizó dentro del conjunto de desarrollo, considerando su comportamiento en horizontes de uno a tres meses, mientras que los resultados definitivos de la evaluación se presentan en el capítulo correspondiente a análisis de resultados.

Descripción del Dataset

La fuente principal de datos de este estudio fue el portal del Sistema de Información Pública Agropecuaria (SIPA, 2026a), administrado por el Ministerio de Agricultura y Ganadería del Ecuador, por tratarse de una fuente oficial que concentra series estadísticas del sector agropecuario a nivel nacional y provincial. La elección de esta fuente se basa en su carácter público, estructurado y periódico, así como su cobertura territorial y temática, lo que la convierte en una base pertinente para el análisis predictivo de precios agrícolas en el contexto ecuatoriano. Además, el SIPA ofrece información complementaria que permite estudiar el comportamiento de los precios no solo desde su trayectoria histórica, sino también desde factores de oferta, costos de producción y contextos macroeconómicos.

Los datos utilizados provienen de los siguientes módulos del SIPA:

- “Precios productor” (SIPA, 2026f)
- “Precios mercados mayoristas y bodegas comerciales” (SIPA, 2026e)
- “Precios agroquímicos y fertilizantes” (SIPA, 2026d)
- “IPC de alimentos e inflación” (SIPA, 2026c)
- “Índices del sector” (SIPA, 2026b)

La elección de los productos Papa Superchola, Tomate Riñón de Invernadero y Maracuyá no fue arbitraria, sino que respondió a criterios de disponibilidad y calidad de información. Se dio prioridad a aquellos productos que contaran con un volumen considerable de registros históricos, presencia sostenida en las distintas fuentes utilizadas, cobertura territorial en múltiples provincias y continuidad temporal lo suficientemente extensa como para construir series consistentes y adecuadas para el entrenamiento y evaluación de modelos predictivos.

Como resultado del proceso de depuración e integración de datos se generó un dataset específico para cada producto. La cobertura temporal obtenida no fue homogénea, debido a las diferencias existentes en la disponibilidad de información comparable entre las fuentes. Papa Superchola cuenta con registros desde enero de 2017 hasta septiembre de 2022, mientras que Tomate Riñón de Invernadero y Maracuyá disponen de información desde enero de 2017 hasta febrero de 2026. Esta diferencia debe considerarse al interpretar los resultados, porque las métricas de distintos productos no representan necesariamente los mismos periodos de tiempo. Por eso, la comparación principal del desempeño se realiza entre modelos aplicados a un mismo producto. La **Tabla 5** resume la composición de los datasets finales.

Tabla 5

Características generales de los datasets finales por producto

Producto	Registros	Provincias	Rango Temporal
Maracuyá	406	5	Enero 2017 a febrero 2026
Papa Superchola	362	8	Enero 2017 a septiembre 2022
Tomate Riñón de Invernadero	482	5	Enero 2017 a febrero 2026

Nota. La cantidad de registros corresponde a los datasets obtenidos luego de las etapas de integración y preprocesamiento, procedimientos que se detallan más adelante.

Cada dataset se organizó como un panel temporal mensual, donde la unidad de observación es la combinación producto-provincia-mes. Esta estructura permite conservar simultáneamente la dimensión temporal y territorial de la información. Para Papa Superchola se

consideraron las provincias de Azuay, Bolívar, Carchi, Cañar, Chimborazo, Cotopaxi, Pichincha y Tungurahua; para Tomate Riñón de Invernadero, Azuay, Chimborazo, Cotopaxi, Imbabura y Tungurahua; y para Maracuyá, Guayas, Los Ríos, Manabí, Santa Elena y Santo Domingo de los Tsáchilas.

Como variable objetivo se definió al precio promedio en USD por kilogramo, obtenida del módulo de precios de mercados mayoristas y bodegas comerciales. Como variables explicativas se incorporaron características temporales, información histórica del propio precio y variables exógenas económicas y sectoriales. Estas últimas comprenden precio productor, precios de fertilizantes, IPC de alimentos, inflación e índices sectoriales.

Los datos recolectados fueron sometidos a procesos de depuración y transformación, eliminando registros no pertinentes y normalizando nombres de columnas, fechas, provincias y productos. El resultado de este proceso fueron datasets estructurados para la aplicación y comparación de los enfoques SARIMAX, LSTM y XGBoost.

Las fuentes de datos, los archivos procesados y el proyecto utilizado para la construcción de los datasets finales se encuentran organizados en el *Apéndice D. Repositorios Digital*, con el propósito de garantizar la trazabilidad, reproducibilidad y documentación del proceso metodológico seguido.

Preparación y Procesamiento de Datos

La preparación y procesamiento de los datos comprendió las etapas necesarias para transformar la información de distintas fuentes en conjuntos consistentes para el entrenamiento y evaluación de los modelos. Debido a que la información proviene de distintos módulos del SIPA, fue necesario estandarizar estructuras, fechas, nombres de productos, provincias, unidades de medida y niveles de agregación previo a integrar las variables en un dataset común.

El procedimiento se realizó preservando la estructura temporal de la información y utilizando como unidad de observación la combinación producto-provincia-mes. Dicho criterio

permitió mantener la relación entre cada producto, su ubicación territorial y el periodo correspondiente, aspecto clave para el análisis de series temporales y para evitar inconsistencias durante la construcción de las características predictivas.

A partir de esta estructura se aplicaron procedimientos de integración, limpieza, tratamiento de valores faltantes, transformación y construcción de variables. También, se adoptaron criterios orientados a preservar el orden cronológico y evitar el uso de información futura durante el procesamiento. Las etapas específicas se describen en las subsecciones siguientes:


Integración de fuentes de datos

La integración de las fuentes de datos se realizó mediante la construcción de una estructura temporal común para la información proveniente de los diferentes módulos del SIPA utilizados. Los registros se organizaron con frecuencia mensual y las fechas se estandarizaron tomando como referencia el primer día del mes, yyyy-MM-01. Este procedimiento permitió alinear temporalmente precios de mercado, precios al productor, fertilizantes, inflación, IPC de alimentos e índices sectoriales.

Para las fuentes que presentaban desagregación territorial, como: precios de mercado y precios al productor, se combinaron producto, provincia y fecha, conservando así la relación territorial y temporal de cada observación y evitando asociar información de provincias o periodos diferentes. La **Figura 1** representa el proceso general de integración de las distintas fuentes.

Figura 1


Proceso de integración de las fuentes de datos del SIPA



Para el caso de las variables sin desagregación territorial, disponibles únicamente a nivel nacional, como: IPC de alimentos, inflación y los índices sectoriales IBC, IPM e IPP-N, la integración se realizó mediante la fecha. El valor nacional correspondiente a cada mes se incorporó a las observaciones provinciales del mismo periodo, permitiendo que cada registro contara con el contexto económico y sectorial vigente. La **Figura 2** detalla dicho procedimiento.

Figura 2


Integración de variables nacionales mediante la fecha



Para las variables relacionadas con fertilizantes se aplicó una estrategia jerárquica de integración debido a las diferencias en su cobertura territorial. Cuando existió información correspondiente a una provincia y mes determinados, se utilizó el valor provincial disponible. En caso de que algún registro no cuente con una coincidencia territorial exacta, se utilizó el valor nacional del mismo periodo como referencia complementaria. Además, se conservaron indicadores que permiten identificar los casos sin coincidencia provincial exacta. La **Figura 3** detalla esta estrategia de integración.

Figura 3

Estrategia jerárquica de integración de las variables de fertilizantes




Como resultado de este proceso, las distintas fuentes quedaron consolidadas en datasets multivariados por producto, provincia y fecha. Los valores que no pudieron completarse durante esta etapa se conservaron como faltantes para ser tratados posteriormente mediante los procedimientos de limpieza y depuración descritos en la siguiente subsección.

Limpieza y depuración de datos

La limpieza y depuración de datos se realizó con el objetivo de garantizar consistencia en la integración de las diferentes fuentes y conservar únicamente registros pertinentes para el análisis. Primero, se estandarizaron nombres de columnas, productos y provincias haciendo uso de normalización de mayúsculas y minúsculas, eliminación de tildes y corrección de espacios, con el fin de homologar denominaciones equivalentes entre los archivos utilizados. La **Figura 4** resume este proceso.

Figura 4

Proceso de estandarización de nombres para la integración de las fuentes de datos



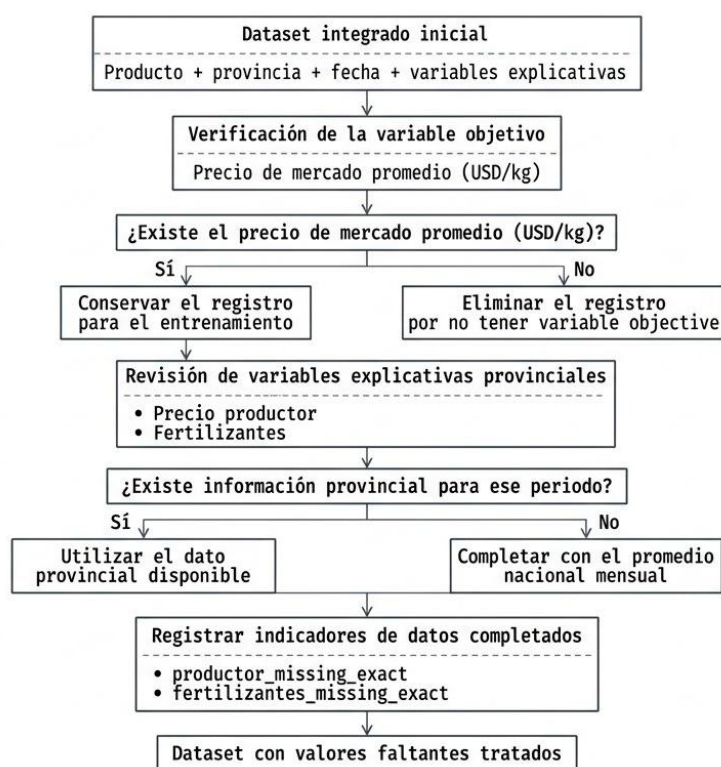
El tratamiento de valores faltantes se definió según la naturaleza de la variable. Se eliminaron aquellos registros que no contaban con precio promedio de mercado en USD/Kg, debido a que esta variable objetivo es indispensable para el entrenamiento y la evaluación de los modelos. Para las variables explicativas, se utilizaron primero los valores territoriales o nacionales disponibles durante la etapa de integración y, cuando para los valores faltantes en la secuencia

temporal, se aplicó propagación hacia adelante, utilizando únicamente información observada en periodos anteriores.

Este procedimiento se aplicó a variables como precio productor, fertilizantes e indicadores macroeconómicos y sectoriales. No se utilizó propagación hacia atrás ni interpolación basada en observaciones posteriores, debido a que estas operaciones podrían incorporar información futura en registros correspondientes a periodos anteriores. Las observaciones que permanecieron sin valor después de estos procedimientos fueron excluidas del conjunto final.

Figura 5

Proceso de tratamiento de valores faltantes en el dataset integrado



Los registros duplicados fueron consolidados a nivel de producto, provincia y fecha. Cuando una misma combinación contenían múltiples observaciones, los precios se agregaron mediante promedios y los campos asociados con frecuencia se cuantificaron, evitando duplicidades sin eliminar información relevante sobre el número de registros disponibles. Respecto a los valores atípicos, no se aplicaron criterios de eliminación automática, debido a que,

en series temporales agrícolas, una observación extrema no necesariamente representa un error, ya que puede corresponder a cambios reales derivados de escasez, estacionalidad, variaciones en la oferta y demanda o modificaciones en los costos de producción (Blázquez-García et al., 2020). Estos valores se conservaron en los datasets finales, de modo que el error predictivo asociado a estas observaciones sea considerado en la evaluación del desempeño de los modelos. La **Figura 6** resume ambos procedimientos.

Figura 6

Proceso de consolidación de registros duplicados y preservación de valores atípicos



La **Tabla 6** muestra el efecto del preprocesamiento, cuantificando observaciones iniciales, eliminadas, registros eliminados por insuficiencia del historial, los valores completados en las principales variables exógenas y el número final de observaciones.

Tabla 6

Resumen cuantitativo del preprocesamiento por producto

Métrica	Maracuyá	Papa Superchola	Tomate Riñón
Registros iniciales	466	458	542
Registros excluidos	60 (12.88%)	96 (20.96%)	60 (11.07%)

Métrica	Maracuyá	Papa Superchola	Tomate Riñón
Precio productor imputado	83 (20.4%)	87 (24.0%)	98 (20.3%)
Fertilizantes imputados	10 (2.5%)	23 (6.4%)	42 (8.7%)
Variables macro completadas	50 (12.3%)	0 (0.0%)	50 (10.4%)
Registros finales	406	362	482

Nota. El porcentaje de excluidos se calcula sobre el total inicial; el de imputación o complemento, sobre el total final de cada producto.

La exclusión de observaciones se debe a que estas no contaban con información histórica previa suficiente para calcular las características temporales requeridas, como rezagos y estadísticas móviles. Asimismo, la cuantificación de los valores completados evidencia diferencias en la disponibilidad de las variables exógenas entre los productos, aspecto que debe considerarse al interpretar los resultados.


Transformación y construcción de variables

Una vez finalizada la limpieza e integración de los datos, se aplicaron transformaciones para unificar la información y construir las características que utilizarían los modelos predictivos. Los precios se unificaron en USD/Kg y las fechas se estandarizaron con frecuencia mensual, tomando como referencia el primer día de cada mes (yyyy-MM-01). Estas transformaciones permitieron mantener una estructura consistente entre productos, provincias y periodos.

A partir de la información temporal se generaron variables de calendario como año, número de mes y trimestre. Asimismo, se incorporaron las transformaciones cíclicas *mes_sin* y *mes_cos*, que permiten representar la periodicidad anual de los meses evitando tratarlos únicamente como valores numéricos consecutivos. La **Figura 7** resume el proceso general de transformación y normalización aplicado a los datos antes de su utilización en los modelos.

Figura 7

Proceso de transformación y normalización de variables



El tratamiento de escala se ajustó a las necesidades de cada modelo. Para LSTM se utilizó MinMaxScaler, con el propósito de llevar las variables numéricas a una escala comparable y facilitar el entrenamiento de la red neuronal. Los escaladores fueron ajustados únicamente con las observaciones pertenecientes al periodo de entrenamiento y posteriormente aplicados a los conjuntos de validación o prueba, evitando que sus parámetros incorporaran información de periodos posteriores. Este procedimiento se repitió en cada ventana de validación temporal.


Posteriormente, se construyeron características para representar el historial del precio: rezagos y estadísticas móviles calculadas por provincia a partir de observaciones anteriores de la variable objetivo, sin incluir el precio del periodo a estimar. El repositorio final documenta estas variables históricas junto con las características de calendario como parte del conjunto utilizado para la configuración base.

A estas variables se añadieron los factores exógenos económicos y sectoriales provenientes de las fuentes integradas, como: precios a nivel productor, información relacionada con fertilizantes, IPC de alimentos, inflación e índices sectoriales. Las variables puramente

contextuales se mantuvieron en los datos, pero se excluyeron del conjunto de características para evaluar el efecto de las exógenas. De esta forma, se definieron dos configuraciones: base, que integra calendario, provincia e historial del precio; y full, que a la configuración base le agrega variables exógenas económicas y sectoriales. La **Figura 8** sintetiza este proceso de construcción de características.

Figura 8

Proceso de construcción de variables temporales y exógenas



Como resultado, se obtuvieron datasets con estructura temporal, histórica y exógena, preservando el orden cronológico necesario para el modelado. Estos conjuntos se utilizaron para entrenar SARIMAX, XGBoost y LSTM en ambas configuraciones.

División cronológica de entrenamiento y prueba

La división de los datos se realizó respetando el orden temporal de las observaciones, debido a que se trabaja con series mensuales de precios agrícolas. A diferencia de una partición aleatoria, la partición cronológica permite entrenar los modelos con información histórica y

evaluarlos sobre periodos posteriores, reduciendo el riesgo de utilizar información futura durante el entrenamiento. (Hyndman & Athanasopoulos, 2021d) resaltan este criterio como fundamental en problemas de series temporales, ya que simula de manera más realista un escenario predictivo.

Para cada producto, los datos se dividieron cronológicamente en dos segmentos: el 80% inicial para el desarrollo de los modelos y el 20% más reciente como conjunto de prueba final. El segmento de desarrollo se usó para entrenamiento, ajuste y validación, mientras que el conjunto de prueba permaneció separado hasta el final.

Dentro del 80% de desarrollo, se implementó una validación temporal mediante ventanas expansivas. En cada ventana, los modelos se entrenaron con un periodo inicial y se evaluaron sobre observaciones posteriores. En ventanas sucesivas, el entrenamiento se amplió progresivamente, permitiendo evaluar el comportamiento en distintos momentos de la serie. Según la disponibilidad de datos, se utilizaron entre dos y tres ventanas de validación.

Las ventanas temporales fueron comunes para SARIMAX, XGBoost y LSTM. Aunque cada modelo tiene una estructura de entrenamiento distinta, los periodos de validación fueron compartidos entre las tres familias. En SARIMAX, las ventanas globales se aplicaron a las observaciones de cada provincia, evitando que cada serie territorial usara cortes temporales diferentes.

Las predicciones generadas durante la validación se relacionaron mediante la combinación producto-provincia-fecha, construyendo una ventana común de validación que permite comparar los modelos con exactamente las mismas observaciones. Esto asegura que las diferencias entre modelos no se deban a variaciones en los registros utilizados.

La última ventana de validación también se usó para evaluar el comportamiento de las configuraciones con variables exógenas en la generación de pronósticos de uno a tres meses, considerando de manera conjunta el error obtenido en estos horizontes. Este procedimiento

permitió seleccionar un único modelo por producto utilizando exclusivamente información contenida en el conjunto de desarrollo.

Finalmente, los modelos seleccionados se ajustaron con todo el conjunto de desarrollo y se evaluaron sobre el 20% reservado como prueba. Este segmento se usó únicamente para reportar el desempeño final, sin intervenir en la selección ni en el ajuste de configuraciones. La **Tabla 7** sintetiza las etapas utilizadas para separar el desarrollo, la validación, la selección operacional y la evaluación final.

Tabla 7

Esquema de partición temporal para entrenamiento, validación y prueba

Etapas	Datos utilizados	Finalidad
Desarrollo	80% inicial	Entrenar y ajustar configuraciones de los modelos.
Validación temporal	Ventanas expansivas dentro del 80% de desarrollo	Evaluar configuraciones y parámetros sobre periodos posteriores al entrenamiento
Validación común	Observaciones coincidentes por producto-provincia-fecha	Comparar las tres familias de modelos sobre las mismas observaciones.
Evaluación operacional	Última ventana de validación	Evaluar pronósticos de uno a tres meses y seleccionar un modelo por producto entre las configuraciones con variables exógenas.
Prueba final	20% más reciente	Evaluar el desempeño final de los modelos sobre datos no utilizados anteriormente.

Nota. Todas las etapas preservan el orden cronológico.

Metodología de Análisis o Modelo

La metodología se diseñó para comparar el desempeño de tres enfoques predictivos y evaluar, de forma independiente, el aporte de las variables exógenas económicas y sectoriales.

Todos los modelos utilizaron como variable objetivo el precio promedio de mercado en USD/Kg y se desarrollaron a partir de los datasets preparados para Papa Superchola, Tomate Riñón de Invernadero y Maracuyá.

En el diseño experimental se consideró: SARIMAX como modelo estadístico de series temporales, XGBoost como modelo de aprendizaje automático y LSTM como modelo de aprendizaje profundo. Debido a las diferencias en el procesamiento de datos de cada enfoque, los procedimientos de entrenamiento se adaptaron a sus características particulares, manteniendo una estrategia temporal común para la validación y evaluación.

Enfoque comparativo de modelado predictivo

La comparación se desarrolló mediante dos configuraciones para cada familia de modelos. La configuración base excluyó las variables exógenas económicas y sectoriales, mientras que la configuración full incluyó las variables exógenas: precio producto, fertilizantes, IPC de alimentos, inflación e índices sectoriales. De esta manera, la comparación entre ambas configuraciones permite analizar el efecto de incorporar esta información complementaria dentro de cada familia de modelos, sin atribuir las diferencias únicamente al tipo de algoritmo.

El diseño experimental comprendió las combinaciones de los tres productos, los tres modelos y las dos configuraciones, dando como resultado 18 combinaciones de entrenamiento y validación. Esta estructura permitió comparar tanto entre configuraciones de una misma familia como entre los diferentes enfoques predictivos.

Tabla 8

Estructura del enfoque comparativo de modelado predictivo

Elemento	Configuración
Productos	Papa Superchola, Tomate Riñón de Invernadero y Maracuyá
Modelos	SARIMAX, XGBoost y LSTM
Configuraciones	Base y full (con variables exógenas)

Elemento	Configuración
Variable objetivo	Precio promedio de mercado en USD/Kg
Estrategia de validación	Validación temporal mediante ventanas expansivas
Horizonte operacional	Uno a tres meses
Combinaciones totales	18

Modelos seleccionados para la comparación

Para representar los tres enfoques metodológicos se utilizaron SARIMAX, XGBoost y LSTM. La selección de estos modelos permite abordar el problema desde perspectivas diferentes: modelado estadístico de series temporales, aprendizaje automático sobre datos estructurados y aprendizaje profundo basado en secuencias temporales.

SARIMAX representa el enfoque estadístico por su capacidad para modelar componentes autorregresivos y estacionales e incorporar variables exógenas. XGBoost representa el aprendizaje automático por su capacidad para trabajar con características temporales, históricas y exógenas en una estructura tabular. LSTM representa el aprendizaje profundo por su capacidad para procesar información mediante secuencias de observaciones anteriores. La **Tabla 9** resume estos modelos y su función dentro del diseño comparativo.

Tabla 9

Modelos seleccionados para la comparación

Modelo	Familia metodológica	Aplicación en el estudio
SARIMAX	Modelo estadístico de series temporales	Modela la dinámica temporal y estacional del precio. Se evalúa en configuración base y con variables exógenas.
XGBoost	Aprendizaje automático supervisado	Utiliza características temporales, históricas y, según la configuración, variables exógenas para estimar el precio.

Modelo	Familia metodológica	Aplicación en el estudio
LSTM	Aprendizaje profundo	Utiliza secuencias temporales para representar la evolución histórica del precio y las variables incluidas en cada configuración.

En tres modelos se evaluaron con las configuraciones base y full con variables exógenas. En SARIMAX, la configuración base corresponde a una formulación sin regresores externos, mientras que la configuración full incorpora los factores económicos y sectoriales mediante su componente exog. En XGBoost y LSTM, ambas configuraciones conservan las características temporales e históricas del precio, diferenciándose por la inclusión de las variables exógenas en la segunda configuración.

Esta estructura permite dos niveles de análisis complementarios: comparar el efecto de las variables exógenas dentro de cada familia y comparar el desempeño de los tres enfoques bajo condiciones temporales equivalente.

Configuración experimental

La configuración experimental se diseñó considerando las particularidades de cada familia de modelos, manteniendo una estructura común de evaluación. Los tres enfoques utilizaron como variable objetivo el precio promedio de mercado en USD/Kg y conservaron la dimensión territorial de los datos, de modo que las predicciones finales correspondieron a combinaciones específicas de producto y provincia.

El nivel de entrenamiento varió según la naturaleza de cada modelo. SARIMAX se ajustó de manera independiente para cada combinación producto-provincia, ya que trabaja directamente sobre la serie temporal de cada provincia. XGBoost y LSTM se entrenaron con un modelo por producto, incorporando la provincia como parte de la estructura de los datos. En LSTM, las secuencias temporales se construyeron de forma independiente dentro de cada provincia para evitar combinar observaciones de territorios diferentes.

Cada modelo se evaluó con las configuraciones base y con variables exógenas. En SARIMAX, las exógenas se incorporaron como regresores externos, en XGBoost y LSTM se incorporaron dentro de sus respectivas estructuras tabular y secuencial. Los tres enfoques compartieron el mismo esquema de separación entre desarrollo y prueba, y las ventanas temporales de validación descritas anteriormente.

La **Tabla 10** resume las principales diferencias en la configuración experimental de los modelos:

Tabla 10

Configuración experimental por modelo

Aspecto	SARIMAX	XGBoost	LSTM
Entrenamiento	Producto-provincia	Producto	Producto
Entrada	Serie temporal + exógenas	Variables tabulares: temporales, históricas y exógenas	Secuencias por provincia
Configuraciones	Base y full	Base y full	Base y full
Nivel de predicción	Producto-provincia	Producto-provincia	Producto-provincia

Esta configuración permitió adaptar el procedimiento de entrenamiento a las características de cada enfoque sin modificar la unidad sobre la cual se generan y evalúan las predicciones. Los parámetros, hiperparámetros y procedimientos específicos utilizados para ajustar cada modelo se describen en las siguientes subsecciones.

Entrenamiento de los modelos

El entrenamiento de los modelos se realizó considerando las características propias de cada enfoque predictivo. Para evitar que la configuración de los modelos dependiera del conjunto de prueba, la selección de parámetros e hiperparámetros se realizó exclusivamente con las ventanas de validación temporal dentro del 80% de desarrollo. Una vez seleccionada la configuración, el

modelo final se ajustó con el conjunto completo de desarrollo y se evaluó sobre el conjunto de prueba.

SARIMAX se entrenó de manera independiente para cada combinación producto-provincia y para las configuraciones base y full. Los parámetros que definen la estructura temporal y estacional de SARIMAX se determinaron mediante una búsqueda entre distintas configuraciones candidatas, seleccionando aquellas con mejor desempeño durante la validación temporal.

XGBoost se entrenó a nivel de producto utilizando las características de cada configuración. Los hiperparámetros se seleccionaron mediante una búsqueda acotada sobre cinco configuraciones candidatas y las ventanas de validación temporal. Además, se incorporó una combinación entre la predicción de XGBoost y el último precio conocido, `target_lag_1`, evaluando pesos de 0.0, 0.1, 0.2 y 0.3 junto con los demás hiperparámetros. El mismo procedimiento se mantuvo en validación y evaluación final, el peso seleccionado para los tres productos fue 0.3.

Para LSTM, las observaciones se organizaron en secuencias temporales independientes por provincia. La configuración de la red se determinó mediante una búsqueda acotada que combinó ventanas de 6, 8 y 10 meses con 32 y 64 unidades LSTM. La tasa de aprendizaje, número de épocas y tamaño de lote se mantuvieron constantes. La selección se basó en el desempeño en validación temporal. Como resultado, se seleccionó una ventana de 8 meses y 32 unidades para Papa Superchola y Tomate Riñón de Invernadero, mientras que para Maracuyá se seleccionó una ventana de 8 meses y 64 unidades.

La **Tabla 11** resume los principales procedimientos empleados para configurar y entrenar cada modelo.

Tabla 11

Configuración general de entrenamiento por modelo

Modelo	Nivel de entrenamiento	Procedimiento de ajuste	Configuración seleccionada
SARIMA X	Producto-provincia	Búsqueda de parámetros mediante validación temporal, independiente para base y full	Parámetros seleccionados para cada serie y configuración
XGBoost	Producto	Búsqueda de hiperparámetros y peso de combinación con target_lag_1	Peso de combinación: 0.3
LSTM	Producto, con secuencias de provincia	6 combinaciones: ventanas (6, 8, 10) * unidades (32, 64)	Papa: 8-32, Tomate: 8-32, Maracuyá: 8-64

La selección realizada durante estas etapas definió la configuración interna de cada modelo. Posteriormente, las configuraciones con variables exógenas se sometieron al procedimiento de evaluación operacional de uno a tres meses.

Métricas y criterios para la comparación de modelos

El desempeño predictivo de los modelos se evaluó con MAE, RMSE, MAPE, R^2 y Directional Accuracy, definidas previamente en el marco teórico. De manera complementaria, se registró n_{test} , correspondiente al número de observaciones utilizadas en el conjunto de prueba de cada evaluación. Estas métricas evalúan el error desde diferentes perspectivas: magnitud, sensibilidad a errores grandes, porcentaje, ajuste y acierto direccional. La evaluación final de cada combinación modelo-producto-configuración se realizó sobre el 20% de prueba. Dado que la cantidad de observaciones puede diferir entre modelos, se construyó una ventana común con observaciones coincidentes por producto, provincia y fecha para comparar cada enfoque sobre los mismos registros.

Para evaluar el aporte de las variables exógenas, se compararon las configuraciones base y full de cada modelo. La diferencia de RMSE se calculó sobre observaciones emparejadas donde

una diferencia positiva indica reducción del error al incorporar dichas variables. La incertidumbre se estimó con block bootstrap pareado de 2000 réplicas y bloques de 4 meses, conservando la dependencia temporal dentro de cada provincia. Se obtuvieron intervalos de confianza del 95% y valores de significancia, ajustados con Holm-Bonferroni para controlar comparaciones múltiples.

Las configuraciones base se utilizaron como grupo de control para evaluar el aporte de las variables exógenas dentro de cada familia de modelos, estableciendo una referencia que permitiera comparar el desempeño con y sin incluir información económica y sectorial. De esta forma, el análisis permitió identificar en qué productos y modelos las variables exógenas produjeron mejoras en el desempeño predictivo y si dichas diferencias presentaron respaldo estadístico.

De forma complementaria, se realizó una selección operacional entre las configuraciones con variables exógenas de los diferentes modelos, con el propósito de determinar qué enfoque presentaba el mejor desempeño para cada producto en pronósticos de uno a tres meses. Para ello, se usó la última ventana de validación del conjunto de desarrollo y se calculó el promedio de RMSE en los tres horizontes (*operational_rmse_mean*). El modelo con el menor RMSE promedio fue seleccionado como referencia para la generación de pronósticos de cada producto, sin utilizar el conjunto de prueba en esta decisión.

La **Tabla 12** resume la función de cada criterio dentro del proceso de evaluación.

Tabla 12

Criterios para evaluación y comparación de modelos

Criterio	Finalidad
MAE, RMSE, MAPE, R^2 y Directional Accuracy	Describir el desempeño predictivo de los modelos.
n_{test}	Indicar el número de observaciones utilizadas en la evaluación.
Ventana común	Comparar los enfoques utilizando las mismas observaciones.
Comparación base vs full	Evaluar el aporte de las variables exógenas dentro de cada modelo.

Criterio	Finalidad
Block Bootstrap + Holm-Bonferroni	Determinar si las diferencias de RMSE presentan respaldo estadístico considerando la dependencia temporal y las comparaciones múltiples.
operational_rmse_mean	Seleccionar un modelo por producto a partir de horizontes de uno a tres meses.

Este procedimiento permite separar la evaluación final de los modelos, el análisis del efecto de las variables exógenas y la selección del modelo utilizado en el prototipo. De esta manera, el conjunto de prueba se reserva exclusivamente para la evaluación final y no participa en las decisiones de ajuste o selección realizadas durante el desarrollo.

Consideraciones para el desarrollo del prototipo web

Como componente aplicado, se desarrolló un prototipo web para consultar y visualizar los pronósticos obtenidos por los modelos. Su función es presentar los resultados de forma accesible, no intervenir en la comparación o selección de modelos. Permite consultas por producto, provincia y horizontes de uno a tres meses.

La selección del modelo para cada producto se realiza antes de su integración en el prototipo, como parte del análisis metodológico. Se comparan las configuraciones con variables exógenas para las tres familias de modelos mediante su desempeño en pronósticos de uno a tres meses. Las configuraciones base actúan como referencia para evaluar el aporte de las variables exógenas. Así, la comparación base vs full mide el efecto de incorporar información económica y sectorial, mientras que la comparación entre modelos en configuración full define el enfoque usado para cada producto.

Una vez seleccionado el modelo para cada producto, este se usa como referencia para generar los pronósticos en el prototipo. La selección se encuentra previamente definida como resultado del proceso experimental, considerando el modelo, la configuración y el criterio de


desempeño establecidos en la metodología. Por esta razón, el prototipo no vuelve a comparar los modelos durante cada consulta, sino que utiliza el resultado obtenido en la etapa de evaluación y selección operacional.

Para pronósticos a varios meses, las variables de calendario se calcular directamente para cada fecha futura, las variables exógenas económicas y sectoriales se mantienen por propagación hacia adelante (carry-forward). Este procedimiento es un supuesto para la generación de los pronósticos y no significa que el sistema prediga el comportamiento futuro de las propias variables exógenas.

En XGBoost y LSTM, los pronósticos se generan recursivamente, es decir, las predicciones de meses anteriores alimentan las siguientes. En SARIMAX, la dinámica autorregresiva maneja la dependencia temporal, y las variables exógenas futuras usan la misma propagación hacia adelante.

Figura 9

Arquitectura del prototipo web para la consulta de predicciones



El prototipo se limita a los productos y provincias del estudio, y es principalmente un medio de consulta y representación de resultados. No reemplaza el análisis comparativo ni constituye un sistema integral para decisiones comerciales.

Capítulo 4. Análisis de Resultados

Presentación general de resultados

En este capítulo se exponen y analizan los resultados obtenidos a partir del entrenamiento y evaluación de los modelos predictivos SARIMAX, XGBoost y LSTM aplicados a la estimación de precios mayoristas de Papa Superchola, Tomate Riñón de Invernadero y Maracuyá en Ecuador. El análisis considera el desempeño de cada familia de modelos y también el efecto de incorporar variables exógenas económicas y sectoriales.

El diseño experimental comprendió 18 combinaciones, resultado de tomar en cuenta tres productos, tres modelos y dos configuraciones de variables diferentes: base y full. La comparación entre configuraciones permite evaluar el aporte de las variables exógenas dentro de cada familia de modelos, por otro lado, la comparación entre modelos en configuración full permite analizar las diferencias de desempeño entre los enfoques considerados.

Los resultados se analizan mediante MAE, RMSE, MAPE, R^2 y Directional Accuracy, complementados con procedimientos estadísticos para determinar si las diferencias observadas presentan evidencia suficiente y no corresponde únicamente a variaciones puntuales del error. Para la comparación entre familias se consideran también ventanas comunes de evaluación, de esta manera los modelos son contrastados sobre las mismas combinaciones de producto, provincia y fecha.

De forma complementaria, se analiza el comportamiento de las configuraciones con variables exógenas en horizontes de pronóstico de uno a tres meses. Con estos resultados se determina el modelo con mejor desempeño operacional para cada producto mediante el promedio del RMSE obtenido en dichos horizontes. Esta selección se basa en el conjunto de desarrollo, mientras que el conjunto de prueba se conserva para reportar el desempeño final.

La presentación de resultados comienza con el comportamiento descriptivo de los precios, el análisis del aporte de las variables exógenas, la comparación entre los modelos y el estudio

particular de cada producto. Posteriormente, se examinan los resultados por provincia, la precisión direccional, los pronósticos en varios horizontes y la visualización de resultados mediante el prototipo web. Finalmente, los hallazgos se integran en la discusión de resultados.

Análisis descriptivo de los precios

Con el fin de contextualizar el comportamiento de las series de precios antes de analizar el desempeño de los modelos, se calcularon estadísticas descriptivas de la variable objetivo (precio promedio de mercado en USD/Kg). Este análisis, **Tabla 13**, permite identificar diferencias en el nivel y la variabilidad de los precios entre los productos considerados.

Tabla 13

Estadísticas descriptivas generales de precios por producto

Producto	Promedio USD/Kg	Mínimo USD/Kg	Máximo USD/Kg	Desviación estándar	Coefficiente variación
Maracuyá	0.6852	0.1800	1.5400	0.2230	32.55%
Papa Superchola	0.4267	0.1620	0.7881	0.1296	30.37%
Tomate Riñón de Invernadero	0.6125	0.3022	1.1722	0.1597	26.07%

La Maracuyá presentó el mayor precio promedio, con 0.69 USD/Kg, seguido por el Tomate Riñón de Invernadero, con 0.61 USD/Kg, y la Papa Superchola, con 0.43 USD/Kg. Estas diferencias son relevantes para la interpretación de las métricas de error, debido a que un mismo error absoluto puede tener distinto peso según el nivel promedio de precio de cada producto.


En términos de la variabilidad relativa, la Maracuyá presentó el mayor coeficiente de variación, con el 32.55%, seguido por la Papa Superchola con el 30.37%, mientras que Tomate Riñón de Invernadero registró el menor valor, con 26.07%. Esta información muestra que la dispersión de los precios no es uniforme entre productos, aunque estas diferencias descriptivas no

determinan por sí solas qué producto es más difícil de predecir, dicho aspecto debe evaluarse con el desempeño de los modelos.

La **Figura 10** complementa este análisis al mostrar la evolución mensual del precio promedio por producto, permitiendo observar cambios en el nivel de precios y periodos de mayor o menor variación a lo largo del tiempo, además de evidenciar que las series presentan comportamientos temporales diferentes.

Figura 10

Evolución mensual del precio promedio de mercado por producto agrícola



En conjunto, las estadísticas descriptivas y la evolución temporal evidencian diferencias en el nivel de dispersión de los precios entre los productos analizados. Estas características contextualizan la interpretación de los resultados predictivos, sin asumir que una mayor variabilidad implique necesariamente un menor desempeño de los modelos.

Interpretabilidad de XGBoost

Como análisis complementario, se examinó la importancia de las variables utilizadas por XGBoost en su configuración con variables exógenas. Para facilitar su interpretación, las características se agruparon en información histórica del precio, calendario y provincia, precio

productor, fertilizantes, IPC, inflación e índices sectoriales. Los porcentajes representan la importancia relativa asignada por el modelo a cada grupo de variables durante el proceso predictivo y no implican relaciones causales con el comportamiento de los precios.

Tabla 14

Importancia relativa de los grupos de variables en XGBoost

Grupo exógeno	Papa Superchola	Tomate Riñón de Invernadero	Maracuyá	Promedio
Precio productor	32.06%	28.57%	9.66%	23.43%
IPC / inflación	3.45%	4.64%	6.88%	4.99%
Índices sectoriales	4.23%	5.17%	4.56%	4.65%
Fertilizantes	2.39%	1.97%	6.31%	3.55%
Total exógenas	42.13%	40.34%	27.41%	36.63%
Historia propia del precio	53.34%	39.74%	68.79%	53.96%
Calendario / provincia	4.53%	19.92%	3.80%	9.42%

En los tres productos, el precio productor fue el grupo exógeno con mayor importancia relativa, con un promedio de 23.43%, superior al obtenido individualmente por los grupos de IPC, inflación, índices sectoriales y fertilizantes. Su participación fue especialmente elevada en Papa Superchola y Tomate Riñón de Invernadero. En Maracuyá, en cambio, predominó la información derivada de la historia propia del precio, que concentró el 68.79% de la importancia.

En conjunto, las variables exógenas representaron el 42.13% de la importancia en Papa Superchola, 40.34% en Tomate Riñón de Invernadero y 27.41% en Maracuyá. Estos resultados muestran que XGBoost utilizó la información exógena en los tres productos, aunque con participación diferente en cada caso. Sin embargo, la importancia dada por cada modelo no implica necesariamente una mejora del desempeño, como es el caso de Maracuyá, donde las variables exógenas fueron utilizadas por XGBoost pero esto no produjo una reducción estadísticamente significativa del error.

Efecto de las variables exógenas

Para determinar el aporte de las variables exógenas, se comparó el RMSE de cada modelo en su configuración base y full con variables exógenas, utilizando las mismas observaciones de prueba. Una diferencia positiva entre el RMSE de la configuración base y full representa una mejora, mientras que una diferencia negativa indica un incremento del error.

La **Tabla 15** representa los resultados obtenidos para las nueve combinaciones de producto y modelo. Además del cambio absoluto y porcentual del RMSE, se incluye el valor p obtenido mediante block bootstrap pareado y el resultado de significancia después de aplicar la corrección de Holm-Bonferroni.

Tabla 15

Efecto de la incorporación de variables exógenas sobre el RMSE

Producto	Modelo	RMSE base	RMSE full	Cambio RMSE	<i>p</i>	Significativo
Maracuyá	XGBoost	0.0952	0.0960	-0.0008 (-0.9%)	0.708	No
Maracuyá	LSTM	0.1322	0.1271	+0.0051 (+3.9%)	0.919	No
Maracuyá	SARIMAX	0.1328	0.1394	-0.0066 (-4.9%)	0.815	No
Papa Superchola	XGBoost	0.0747	0.0594	+0.0153 (+20.4%)	< 0.001	Sí
Papa Superchola	LSTM	0.1318	0.0972	+0.0346 (+26.3%)	0.099	No
Papa Superchola	SARIMAX	0.1465	0.0801	+0.0664 (+45.3%)	< 0.001	Sí
Tomate Rinón de Invernadero	XGBoost	0.1061	0.0804	+0.0257 (+24.2%)	< 0.001	Sí
Tomate Rinón de Invernadero	LSTM	0.1227	0.0825	+0.0402 (+32.8%)	< 0.001	Sí

Producto	Modelo	RMSE base	RMSE full	Cambio RMSE	<i>p</i>	Significativo
Tomate Riñón de Invernadero	SARIMAX	0.1521	0.1074	+0.0447 (+29.4%)	0.004	Sí

Nota. Un cambio positivo representa una reducción del RMSE al incorporar variables exógenas.

Para Papa Superchola, los tres modelos redujeron el RMSE al incorporar variables exógenas, sin embargo, el análisis estadístico mostró diferencias significativas únicamente para SARIMAX y XGBoost. Para Tomate Riñón de Invernadero, igualmente los tres modelos mejoraron su RMSE en configuración full, además de que todas las diferencias fueron estadísticamente significativas, proporcionando evidencia de un aporte favorable de la información económica y sectorial sobre el desempeño predictivo. Por último, en Maracuyá el efecto de incluir variables exógenas fue menor, solo LSTM redujo el error mientras que en los otros dos modelos aumentó, ninguna diferencia fue significativa para este producto.

En conjunto, 5 de las 9 comparaciones mostraron mejoras significativas: dos en Papa Superchola, 3 en Tomate Riñón de Invernadero y ninguna en Maracuyá. Por lo tanto, los resultados muestran que el aporte de las variables exógenas no fue uniforme, dependiendo del producto y de la familia de modelo considerada.

Evaluación comparativa de modelos

Una vez analizado el efecto de las variables exógenas dentro de cada familia de modelos, se comparó el desempeño de SARIMAX, XGBoost y LSTM en sus configuraciones full con variables exógenas, utilizando una ventana común del conjunto de prueba, construida a partir de las observaciones coincidentes por producto, provincia y fecha. De esta manera, la **Tabla 16** muestra las diferencias entre modelos analizados sobre exactamente los mismos registros para cada producto.

Tabla 16

Resultados comparativos de los modelos con variables exógenas

Producto	Modelo	MAE	RMSE	MAPE	R ²	Directional Accuracy	n _{test}
Maracuyá	XGBoost	0.0758	0.0960	10.41%	0.5695	89.02%	83
Maracuyá	LSTM	0.0979	0.1271	13.45%	0.2458	65.85%	83
Maracuyá	SARIMAX	0.1031	0.1394	12.83%	0.0930	67.07%	83
Papa Superchola	XGBoost	0.0467	0.0608	8.54%	0.8168	88.57%	71
Papa Superchola	LSTM	0.0780	0.0986	18.48%	0.5180	68.57%	71
Papa Superchola	SARIMAX	0.0606	0.0801	11.92%	0.6818	80.00%	71
Tomate Riñón de Invernadero	XGBoost	0.0644	0.0804	10.74%	0.7629	85.57%	98
Tomate Riñón de Invernadero	LSTM	0.0667	0.0825	11.35%	0.7507	73.20%	98
Tomate Riñón de Invernadero	SARIMAX	0.0912	0.1074	14.00%	0.5768	81.44%	98

Nota. Los resultados corresponden exclusivamente a la configuración full y a las observaciones comunes de prueba para los tres modelos dentro de cada producto.

En Papa Superchola, XGBoost presentó los mejores resultados para todas las métricas. Sin embargo, al analizar estadísticamente sola la diferencia entre XGBoost y LSTM fue significativa, las diferencias con SARIMAX no alcanzan la significancia suficiente. Esto índice que, aunque XGBoost obtuvo mejores valores numéricos, no se puede afirmar con la misma certeza que su desempeño haya sido superior al de SARIMAX.

En Tomate Riñón de Invernadero, XGBoost y LSTM mostraron resultados cercanos, sin diferencia significativa entre ellos. SARIMAX tuvo un RMSE mayor, significativo frente a los otros modelos. Así, SARIMAX mostró un menor desempeño, sin evidencia suficiente para afirmar superioridad de XGBoost sobre LSTM.

En Maracuyá, XGBoost obtuvo los menores errores y el mayor R². Las diferencias de RMSE entre XGBoost y LSTM, y entre XGBoost y SARIMAX, fueron significativas; la

diferencia entre LSTM y SARIMAX no. Estos resultados respaldan una ventaja de XGBoost para este producto sobre los otros modelos.

En conjunto, XGBoost tuvo el menor RMSE puntual en la ventana común de prueba para los tres productos. Pero esto no implica superioridad estadística en todos los casos: la magnitud y significancia de las diferencias dependen del producto y del modelo comparado.

Análisis de resultados por producto


Papa Superchola

Para este producto, las variables exógenas redujeron el RMSE en las tres familias de modelos: 20.4% para XGBoost, 26.3% para LSTM y 45.3% para SARIMAX. La mejora fue significativa solo en XGBoost y SARIMAX; en LSTM, aunque se redujo el error, este no alcanzó significancia estadística.

Comparando los tres modelos con variables exógenas sobre las mismas 71 observaciones de prueba, XGBoost obtuvo los mejores resultados en todas las métricas: MAE de 0.0467 USD/Kg, RMSE de 0.0608, MAPE de 8.54%, R^2 de 0.8168 y Directional Accuracy de 88.57%. SARIMAX y LSTM alcanzaron RMSE de 0.0801 y 0.0986, respectivamente. XGBoost tuvo una ventaja numérica, solo confirmada estadísticamente frente a LSTM. La **Figura 11** complementa estos resultados comparando precios reales y predichos durante el periodo de prueba.

Figura 11

Comparación de precios reales y predichos para Papa Superchola



En conjunto, XGBoost presentó el mejor desempeño predictivo para Papa Superchola en la comparación realizada. Las variables exógenas mejoraron las tres familias de modelos, pero con distinto respaldo estadístico, evidenciando que su efecto depende también del modelo utilizado.

Tomate Riñón de Invernadero


Para este producto, las variables exógenas redujeron el RMSE en los tres modelos: 24.2% para XGBoost, 32.8% para LSTM y 29.4% para SARIMAX. Las diferencias fueron significativas, evidenciando un aporte favorable de la información económica y sectorial para este producto.

Comparando las configuraciones full sobre las mismas 98 observaciones de prueba, XGBoost obtuvo MAE de 0.0644 USD/Kg, RMSE de 0.0804, MAPE de 10.74%, R^2 de 0.7629 y Directional Accuracy de 85.57%. LSTM mostró resultados muy cercanos con RMSE de 0.0825 y R^2 de 0.7507, mientras que SARIMAX registró errores superiores con RMSE 0.1074 y R^2 0.5768.

Las diferencias entre XGBoost y LSTM no fue significativa, pero las diferencias de SARIMAX frente a los otros modelos sí lo fueron. Por tanto, XGBoost y LSTM mostraron un desempeño similar, mientras que SARIMAX fue inferior. La **Figura 12** complementa este análisis comparando precios reales y predichos durante el periodo de prueba.

Figura 12

Comparación de precios reales y predichos para Tomate Riñón de Invernadero



En conjunto, este producto tuvo el aporte más consistente de las variables exógenas, las tres familias de modelos redujeron significativamente su RMSE. XGBoost obtuvo los mejores valores numéricos, pero sin diferencias significativas frente a LSTM; en cambio, SARIMAX mostró un menor desempeño frente a ambos.

Maracuyá


Para este producto, las variables exógenas produjeron cambios pequeños en el RMSE: en XGBoost aumentó un 0.9%, y en SARIMAX 4.9%, mientras que LSTM redujo 3.9%. Ninguna diferencia fue estadísticamente significativa, por lo que no hay evidencia de mejora al incorporar exógenas es este producto.

Comparando las configuraciones full sobre las mismas 83 observaciones de prueba, XGBoost obtuvo el mejor desempeño: MAE de 0.0758 USD/Kg, RMSE de 0.0960, MAPE de 10.41%, R^2 de 0.5695 y Directional Accuracy de 89.02%.

Las diferencias de XGBoost frente a los otros modelos fueron significativas. Así, XGBoost mostró un desempeño claramente superior para Maracuyá. La **Figura 13** complementa este análisis comparando precios reales y predichos durante el periodo de prueba.

Figura 13

Comparación de precios reales y predichos para Maracuyá



En conjunto, XGBoost fue el modelo con mejor desempeño para Maracuyá, aunque las variables exógenas no produjeron mejoras significativas en ninguna familia de modelos. Esto demuestra que un modelo puede tener buen desempeño frente a otros incluso sin que las variables exógenas mejoren su propia configuración base.

Selección operacional de modelos por producto

Adicionalmente a la evaluación del aporte de las variables exógenas y la comparación entre modelos, se realizó una selección operacional para determinar qué enfoque presentaba el mejor desempeño en pronóstico de uno a tres meses para cada producto. Solo se consideraron las configuraciones con variables exógenas de las tres familias de modelos; las configuraciones base, usadas como referencia para el análisis comparativo de configuraciones, no participaron.

La selección se basó exclusivamente en la última ventana de validación del conjunto de desarrollo, sin utilizar el conjunto de prueba. Para cada modelo se generaron pronósticos a 1, 2 y 3 meses, se calculó el RMSE en cada horizonte y se promediaron los tres valores para obtener el RMSE operacional promedio. El modelo con el menor valor fue seleccionado para cada producto.

Tabla 17

Desempeño operacional de los modelos con variables exógenas por producto

Producto	Modelo	RMSE operacional promedio	Seleccionado
Maracuyá	XGBoost	0.1578	Sí
Maracuyá	LSTM	0.1847	No
Maracuyá	SARIMAX	0.2021	No
Papa Superchola	XGBoost	0.0632	Sí
Papa Superchola	LSTM	0.0664	No
Papa Superchola	SARIMAX	0.116	No
Tomate Riñón de Invernadero	XGBoost	0.0957	No
Tomate Riñón de Invernadero	LSTM	0.0831	Sí
Tomate Riñón de Invernadero	SARIMAX	0.0882	No

Nota. Selección únicamente sobre configuración full. RMSE operacional promedio extraído de la variable operational_rmse_mean del repositorio.

Para Papa Superchola, XGBoost presentó el mejor desempeño operacional entre las configuraciones con variables exógenas evaluadas para los pronósticos de uno a tres meses. En Tomate Riñón de Invernadero, aunque XGBoost obtuvo un RMSE ligeramente menor en el conjunto de prueba, la selección operacional basada en el desempeño de los tres horizontes de validación determinó que LSTM fue mejor. Para Maracuyá, XGBoost volvió a mostrar el mejor desempeño operacional.

En conjunto, la evaluación operacional determinó que XGBoost presentó el mejor desempeño para Papa Superchola y Maracuyá, mientras que LSTM obtuvo el mejor resultado para Tomate Riñón de Invernadero, considerando las configuraciones con variables exógenas y los pronósticos de uno a tres meses. Estos resultados complementan el análisis del aporte de las variables exógenas y la evaluación final de los modelos, ya que permite identificar el enfoque con mejor desempeño operacional para cada producto bajo las condiciones establecidas en el estudio.

Análisis complementario por provincia

Debido a que las predicciones se realizan a nivel de producto y provincia, se examinó de forma complementaria el comportamiento de los modelos en las diferentes provincias incluidas en

el estudio. Para mantener la homogeneidad, se consideraron únicamente las observaciones de prueba que coinciden en los tres enfoques de modelos y se utilizó el RMSE como referencia. Este análisis tiene un carácter descriptivo y busca identificar posibles diferencias territoriales en el desempeño de los modelos.

Para Maracuyá, la **Tabla 18** muestra como el modelo con mejor desempeño varía según la provincia. Para este producto analizaremos el caso particular de la provincia de Santa Elena con ayuda de la **Figura 14**. XGBoost obtuvo el menor RMSE con un 0.1434 sobre 11 observaciones comunes, aunque este valor fue mayor que el de las otras provincias, mostrando que el nivel de error puede variar territorialmente incluso con el mismo modelo. Dado el reducido número de observaciones, este resultado es descriptivo, no es una evidencia de mayor dificultad predictiva en dicha provincia.

Tabla 18


Modelo con menor RMSE por provincia para Maracuyá

Provincia	Modelo	RMSE	<i>n</i>
Guayas	XGBoost	0.1025	22
Los Ríos	XGBoost	0.0614	12
Manabí	SARIMAX	0.0608	19
Santa Elena	XGBoost	0.1434	11
Santo Domingo de los Tsáchilas	LSTM	0.0683	19

Nota. El valor *n* corresponde al número de observaciones comunes utilizados para comparar los tres modelos en cada provincia.

Figura 14

Comparación de precios reales y predichos para Maracuyá en Santa Elena



El conjunto completo de gráficos por provincia para Maracuyá se incluye en el *Apéndice*

A. Análisis provincial para Maracuyá.

Para Papa Superchola, la **Tabla 19** muestra como XGBoost obtuvo el mejor desempeño para la mayoría de las provincias. La **Figura 15** permite observar un caso donde el resultado provincial difiere de la selección consolidada por producto. Se analizó Azuay, donde LSTM obtuvo el menor RMSE provincial con 0.0841 sobre 14 observaciones comunes, difiriendo del comportamiento agregado del producto donde XGBoost fue el mejor operacionalmente. Esto evidencia que el mejor modelo general no necesariamente lo es en cada territorio.

Tabla 19


Modelo con menor RMSE por provincia para Papa Superchola

Provincia	Modelo	RMSE	<i>n</i>
Azuay	LSTM	0.0841	14
Carchi	XGBoost	0.0356	10
Chimborazo	SARIMAX	0.0394	11
Cotopaxi	XGBoost	0.0458	11
Pichincha	XGBoost	0.0605	14
Tungurahua	XGBoost	0.0476	11

Nota. El valor n corresponde al número de observaciones comunes utilizados para comparar los tres modelos en cada provincia.

Figura 15

Comparación de precios reales y predichos para Papa Superchola en Azuay



Las provincias de Bolívar y Cañar no fueron incluidas en el análisis comparativo provincial para Papa Superchola, debido a que no disponían de observaciones de prueba coincidentes para los tres modelos. El conjunto completo de gráficos por provincia para Papa Superchola se incluye en el **Apéndice B. Análisis provincial para Papa Superchola**.

Para Tomate Riñón de Invernadero, la **Tabla 20** muestra el mejor desempeño de los modelos por provincia. La **Figura 16** expone a Cotopaxi como un buen caso de análisis, en esta provincia SARIMAX obtuvo el menor RMSE con 0.0748 sobre 19 observaciones comunes, que también difiere de la selección operacional del producto, donde fue LSTM el adecuado. Esto refuerza la existencia de variaciones territoriales y muestra que los resultados agregados pueden diferir del análisis por provincia.

Tabla 20


Modelo con menor RMSE por provincia para Tomate Riñón de Invernadero

Provincia	Modelo	RMSE	<i>n</i>
Azuay	XGBoost	0.0894	22
Chimborazo	XGBoost	0.0602	19
Cotopaxi	SARIMAX	0.0748	19
Imbabura	LSTM	0.0829	19
Tungurahua	XGBoost	0.0650	19

Nota. El valor *n* corresponde al número de observaciones comunes utilizados para comparar los tres modelos en cada provincia.

Figura 16

Comparación de precios reales y predichos para Tomate Riñón de Invernadero en Cotopaxi



El conjunto completo de gráficos por provincia para Tomate Riñón de Invernadero se incluye en el *Apéndice C. Análisis provincial para Tomate Riñón de Invernadero*.

Ninguna familia de modelos fue la mejor en todas las provincias. Estas diferencias complementan los resultados por producto y evidencian que el desempeño predictivo puede variar territorialmente. Sin embargo, debido al número limitado de observaciones en algunas provincias y a que no se realizó una validación espacial con provincias fuera del entrenamiento, estos resultados deben interpretarse de manera exploratoria, no como evidencia de generalización a nuevos territorios.


Precisión direccional como análisis complementario

La Directional Accuracy complementa las métricas de error al evaluar si el modelo acierta correctamente la dirección del cambio del precio respecto al periodo anterior. Un modelo puede tener estimaciones cercanas al valor real y, sin embargo, diferente capacidad para anticipar si el precio sube o baja.

La **Figura 17** permite observar si el modelo con menor error numérico coincide con el modelo que mejor sigue la dirección del precio.

Figura 17

Comparación entre RMSE y Directional Accuracy por producto y modelo



Nota. Los valores corresponden a la ventana común de prueba, comparando los tres modelos sobre las mismas observaciones dentro de cada producto.

XGBoost obtuvo la mayor precisión direccional en los tres productos, coincidiendo con sus bajos RMSE en la evaluación de prueba. Sin embargo, esta métrica es tomada como complementaria y no fue el criterio de selección operacional. Por ejemplo, en Tomate Riñón de Invernadero, LSTM fue seleccionado por su mejor RMSE operacional promedio en horizontes de uno a tres meses, aunque XGBoost sea el modelo con el mayor Directional Accuracy en prueba.

Esta métrica complementa el análisis de precisión incorporando la capacidad de anticipar la tendencia del precio.

Análisis por horizonte de pronóstico

Para analizar cómo cambia el desempeño de los modelos con la distancia de predicción, se evaluaron las configuraciones con variables exógenas en horizontes de 1, 2 y 3 meses sobre el conjunto de prueba.

Tabla 21

RMSE por producto, modelo y horizonte de pronóstico

Producto	Modelo	1 mes	2 meses	3 meses
Maracuyá	XGBoost	0.1027	0.1347	0.1482
Maracuyá	LSTM	0.1407	0.1662	0.1866
Maracuyá	SARIMAX	0.1055	0.1238	0.1271
Papa Superchola	XGBoost	0.0653	0.0923	0.1085
Papa Superchola	LSTM	0.1157	0.1555	0.1762
Papa Superchola	SARIMAX	0.1360	0.1100	0.1912
Tomate Rinón de Invernadero	XGBoost	0.1230	0.1639	0.2031
Tomate Rinón de Invernadero	LSTM	0.1188	0.1442	0.1827
Tomate Rinón de Invernadero	SARIMAX	0.1141	0.1372	0.1770

Nota. Los valores corresponden a configuraciones full. Menor valor significa menor error.

En Papa Superchola, XGBoost tuvo el menor RMSE en los tres horizontes, aumentando de 0.0653 en el primer mes a 0.1085 en el tercer horizonte. LSTM mostró comportamiento similar y SARIMAX tuvo una evolución menos uniforme, reduciendo a 2 meses y luego incrementando fuertemente a 3 meses.

En Tomate Riñón de Invernadero, los tres modelos incrementaron su RMSE con cada horizonte. SARIMAX presentó los menores valores en esta evaluación, seguido de LSTM y, por último, XGBoost. Estos resultados no modifican la selección operacional previa, ya que esa selección se basó en la validación, mientras que esta tabla corresponde a prueba.

En Maracuyá, XGBoost fue menor a 1 mes, mientras que SARIMAX lo fue a 2 y 3 meses. LSTM registró los valores más altos en los tres horizontes. El desempeño relativo de los modelos cambio según la distancia temporal considerada.

En general, el RMSE tendió a incrementarse con el horizonte, con algunas excepciones. Este comportamiento debe interpretarse considerando que las variables exógenas futuras se mantienen en su último valor disponible, y que en XGBoost y LSTM los errores pueden acumularse progresivamente al ser recursivos.

Resultados del prototipo web

Como componente aplicado, se implementó un prototipo web para consultar y visualizar los pronósticos de precios agrícolas. La interfaz permite seleccionar producto, provincia y horizonte de pronóstico, 1 a 3 meses, mostrando la estimación en USD/Kg.

La **Figura 18** muestra la pantalla de consulta, con las opciones para definir el escenario de predicción. Las provincias disponibles dependen del producto seleccionado y corresponden a los territorios incluidos en los datasets del estudio.

Figura 18

Pantalla de selección de producto, provincia y horizonte de predicción

¿CÓMO FUNCIONA?

Realiza una consulta en cuatro pasos

- 1 Selecciona un producto**
Elige el producto agrícola cuyo precio deseas consultar.
- 2 Elige una provincia**
Selecciona la provincia para la que deseas conocer la proyección.
- 3 Define el período**
Indica si deseas conocer la proyección para 1, 2 o 3 meses.
- 4 Genera la predicción**
El sistema analizará la información y mostrará el precio estimado y su posible tendencia.

Después de generar la predicción podrás consultar el último precio conocido, el precio estimado, su posible variación y una explicación sencilla de la tendencia.

CONSULTA DE PRECIO

¿Qué precio deseas consultar?

Selecciona el producto, la provincia y el período que deseas analizar. El sistema utilizará automáticamente el modelo más adecuado para realizar la estimación.

Producto agrícola:

Provincia:

Período de proyección:

Generar predicción


La estimación se mostrará en USD/kg e incluirá una explicación sencilla de la tendencia esperada.

Una vez establecidos los parámetros de consulta, el sistema genera el pronóstico usando el modelo preseleccionado para cada producto mediante la evaluación operacional. El usuario no selecciona ni compara modelos en la interfaz, ya que esa decisión corresponde al procedimiento experimental.

La **Figura 19** muestra un ejemplo del resultado generado. Además del precio estimado, la interfaz presenta gráficamente la evolución histórica y los valores pronosticados para el horizonte seleccionado.

Figura 19

Resultado de la predicción



De manera complementaria, la **Figura 20** muestra como la interfaz puede presentar las métricas obtenidas por el modelo utilizado para el producto seleccionado, con el propósito de brindar al usuario información complementaria sobre su desempeño durante la evaluación.

Figura 20

Métricas de desempeño mostradas en el prototipo



Los resultados son predicciones puntuales y deben interpretarse bajo las condiciones metodológicas establecidas. Para horizontes futuros, las variables exógenas no disponibles mantienen su último valor conocido. El prototipo es principalmente un medio para hacer accesibles y visuales los resultados predictivos, sin sustituir el análisis comparativo entre modelos.

Discusión de resultados

Los resultados muestran que el desempeño predictivo depende del producto, el modelo y la información incorporada. De las 9 comparaciones base vs full con variables exógenas, 5 presentaron mejoras significativas, 3 en Tomate Riñón de Invernadero y 2 en Papa Superchola; con la particularidad de que en Maracuyá ninguna fue significativa. Por tanto, la incorporación de variables exógenas no fue uniformemente beneficiosa.

Este comportamiento coincide con la literatura revisada, donde se reconoce que la información externa puede complementar el historial de precios, pero su aporte depende de la serie, las variables y el enfoque utilizado. (Gu et al., 2022) y (Nayak et al., 2024) respaldan el uso de información adicional, pero los resultados del presente estudio demuestran que su beneficio debe evaluarse empíricamente, no asumirse en todos los productos.

En la ventana común de prueba, XGBoost obtuvo el menor RMSE en los tres productos, aunque las pruebas estadísticas indicaron que estas ventajas no fueron significativas en todas las comparaciones. Esto refuerza que la superioridad de un modelo no debe determinarse solo por diferencias numéricas mínimas, sino considerando su incertidumbre asociada.

La selección operacional muestra que XGBoost fue el mejor para Papa Superchola y Maracuyá, mientras que LSTM lo fue para Tomate Riñón de Invernadero. Esto demuestra que el modelo con menor error en prueba no necesariamente coincide con el mejor comportamiento en pronósticos consecutivos de corto plazo. Por ello, no se puede confirmar a una única familia como superior bajo todos los criterios.

El análisis por horizonte evidencia una tendencia general al incremento del error conforme la predicción se extiende de 1 a 3 meses, con excepciones según producto y modelo. Esto puede relacionarse con la mayor incertidumbre en periodos alejados y con los supuestos metodológicos: las variables exógenas no disponibles se mantienen en su último valor conocido, y XGBoost y LSTM usan progresivamente las predicciones anteriores para los siguientes horizontes.

La dimensión territorial también mostró que el mejor modelo para un producto no siempre coincide con el mejor en cada provincia. Sin embargo, debido al reducido número de observaciones en algunos territorios, estos resultados provinciales son complementarios y no es conveniente generalizarlos hacia provincias no entrenadas.

En relación con la hipótesis, los resultados proporcionan un respaldo parcial. Las variables exógenas mejoraron significativamente 5 de 9 combinaciones, beneficiando consistentemente a

Tomate Riñón de Invernadero y parcialmente a Papa Superchola; Maracuyá no tuvo evidencia de mejora. La hipótesis no se confirma de manera general, pero sí se obtiene evidencia de que las variables económicas y sectoriales pueden mejorar el desempeño en determinadas condiciones.

Finalmente, los resultados deben interpretarse dentro del alcance establecido por este estudio: la cobertura temporal difiere entre productos, algunas provincias tienen observaciones limitadas, y el estudio no evaluó provincias completamente excluidas del entrenamiento. Los pronósticos son puntuales limitando la generalización, pero no afectan el objetivo comparativo dentro de los productos, provincias y periodos efectivamente analizados.

Capítulo 5. Conclusiones y Recomendaciones

Conclusiones

La evaluación comparativa de modelos estadísticos, de aprendizaje automático y de aprendizaje profundo permitió identificar diferencias relevantes en la predicción de precios mayoristas agrícolas en Ecuador. Los resultados mostraron que el desempeño de los modelos varía según el producto analizado, por lo que no existe un único enfoque ideal para todos los casos. XGBoost presentó el mejor desempeño operacional para Maracuyá y Papa Superchola, mientras que LSTM obtuvo el mejor resultado para Tomate Riñón de Invernadero.

Se recopilaron, depuraron e integraron series temporales de precios mayoristas y variables exógenas económicas y sectoriales para los productos seleccionados. Se construyeron datasets a partir de las fuentes del SIPA, consolidando una estructura mensual basada en producto, provincia y fecha, lo que permitió conservar las dimensiones temporal y territorial del problema. Sin embargo, la cobertura temporal no fue homogénea: Papa Superchola contó con información hasta septiembre de 2022, a diferencia de Maracuyá y Tomate Riñón de Invernadero, que contaron con registros hasta febrero de 2026.

Se diseñaron, entrenaron y compararon tres enfoques de modelado: SARIMAX como referencia estadística, XGBoost como modelo de aprendizaje automático y LSTM como modelo de aprendizaje profundo. Los tres enfoques se evaluaron mediante una configuración base y una configuración full con variables exógenas. La configuración base excluyó las variables económicas y sectoriales, mientras que la configuración full incorporó información de precio productor, fertilizantes, IPC de alimentos e índices sectoriales. Esta estructura permitió evaluar el aporte de dichas variables dentro de cada familia de modelos, diferenciándolo de las características propias de cada enfoque.

La selección operacional se realizó exclusivamente dentro del conjunto de desarrollo, utilizando el RMSE promedio obtenido en los horizontes de uno, dos y tres meses, sin emplear el

conjunto de prueba para tomar esta decisión. Bajo este criterio, XGBoost presentó el mejor desempeño operacional para Papa Superchola y Maracuyá, mientras que LSTM obtuvo el mejor resultado para Tomate Riñón de Invernadero. En este último producto, XGBoost presentó un RMSE ligeramente menor en el conjunto de prueba, sin embargo, LSTM mostró un mejor desempeño conjunto en los horizontes considerados durante la validación. Este resultado evidencia que la evaluación de los modelos debe considerar el objetivo predictivo y no limitarse a una única métrica.

El prototipo web permitió representar de forma accesible los resultados predictivos mediante consultas por producto, provincia y horizonte de pronóstico. Su implementación se realizó como un componente complementario para la consulta y visualización de los resultados obtenidos en la investigación.

Respecto a la hipótesis planteada, los resultados mostraron un respaldo parcial. La incorporación de variables exógenas produjo mejoras estadísticamente significativas en 5 de las 9 combinaciones producto-modelo evaluadas: los tres modelos para Tomate Riñón de Invernadero y, SARIMAX y XGBoost para Papa Superchola. Aunque LSTM también redujo su error en Papa Superchola, esta mejor no alcanzó significancia estadística. En Maracuyá, ninguna de las tres familias de modelos presentó mejoras significativas al incorporar variables exógenas. Por tanto, el aporte de la información económica y sectorial dependió del producto y del modelo utilizado, y no puede generalizarse como una mejora uniforme para todos los escenarios analizados.

En conjunto, los resultados evidencian que la predicción de precios agrícolas requiere un enfoque flexible y diferenciado por producto. Las características de las series, las diferencias territoriales, la cobertura temporal y la disponibilidad de información deben considerarse al interpretar el desempeño de los modelos. Por ello, realizar una selección específica para cada producto es más adecuado que asumir la superioridad de un único enfoque o un efecto uniforme de las variables exógenas en todos los casos analizados.

Recomendaciones

Se recomienda actualizar periódicamente los conjuntos de datos con información de fuentes oficiales, dado que los precios agrícolas responden a condiciones económicas, productivas, climáticas y comerciales cambiantes. Esta actualización permitiría reentrenar los modelos y mantener vigente su capacidad predictiva.

Se recomienda ampliar el estudio incorporando otros productos agrícolas de relevancia comercial en Ecuador, con el fin de evaluar si el comportamiento observado en Papa Superchola, Tomate Riñón de Invernadero y Maracuyá se mantiene en productos con distintos niveles de estacionalidad, volatilidad, cobertura territorial y disponibilidad de datos.

Se recomienda ampliar el conjunto de variables exógenas consideradas, incorporando información climática, volúmenes de producción, indicadores de oferta y demanda, costos de transporte, costos de producción y otros eventos externos relevantes para la formación de precios. Esto es particularmente relevante para Maracuyá, el único producto en el que la incorporación de las variables exógenas actualmente utilizadas (precio productor, fertilizantes, IPC/inflación e índices sectoriales) no produjo mejoras significativas en ninguna familia de modelos. Este resultado no implica que las variables exógenas sean irrelevantes para Maracuyá, sino que el conjunto de variables empleado podría no capturar los factores que explican su variabilidad, y que un conjunto distinto podría ofrecer resultados diferentes.

Se recomienda extender la validación mediante un esquema leave-one-province-out, que permitiría evaluar el desempeño del modelo en provincias no utilizadas durante el entrenamiento. Al combinar este esquema con la validación temporal por ventanas expansivas, sería posible distinguir si la capacidad predictiva del modelo depende del tiempo, del territorio, o de ambos factores.

Futuras versiones del estudio podrían explorar el entrenamiento de modelos específicos por provincia, considerando que el análisis mostró variaciones territoriales en el desempeño. Esta

estrategia requeriría contar con un volumen suficiente de información histórica en cada territorio para garantizar un proceso de entrenamiento y evaluación adecuado.

En XGBoost, el peso de combinación seleccionado fue 0.3, correspondiente al límite superior del rango evaluado entre 0.0 y 0.3. Por ello, futuras investigaciones podrían ampliar esta búsqueda hacia valores superiores para determinar si existen configuraciones con mejor desempeño. En LSTM, podría extenderse la optimización a parámetros como: tasa de aprendizaje, número de capas recurrentes y estrategias de regulación.

Se recomienda que el prototipo web incorpore un proceso de monitoreo continuo que compare las predicciones con los precios reales observados, permitiendo detectar cuándo el desempeño del modelo se deteriora y cuándo es necesario un reentrenamiento ante cambios en el mercado.

Aunque el estudio incorporó estimaciones de incertidumbre mediante bootstrap para las comparaciones estadísticas del RMSE, este procedimiento no proporciona un intervalo de incertidumbre para cada predicción individual. Se recomienda que futuras versiones del prototipo incorporen intervalos predictivos junto con las estimaciones puntuales, de modo que el usuario final pueda interpretar la incertidumbre asociada al pronóstico. Esto resulta especialmente relevante en productos de alta variabilidad, donde un valor puntual puede dificultar la interpretación.

Se recomienda evaluar la viabilidad de desplegar el prototipo en un entorno de producción, considerando los requerimientos de actualización de datos, reentrenamiento, monitoreo del desempeño y estabilidad del sistema. Esto permitiría analizar posteriormente su utilización como herramienta de consulta y visualización en contextos reales del sector agrícola.

Finalmente, se recomienda utilizar los resultados de este estudio como apoyo a la predicción y no como explicación causal del comportamiento de los precios. Los modelos identifican patrones y relaciones a partir de información histórica, pero los precios agrícolas

pueden verse afectados por factores no incluidos en los datos disponibles. Por ello, las predicciones deben emplearse como un insumo complementario al criterio técnico, al conocimiento del mercado y al análisis del contexto productivo y comercial.

Referencias Bibliográficas

- Adi, R. M. S., & Sudianto, S. (2022). Prediksi Harga Komoditas Pangan Menggunakan Algoritma Long Short-Term Memory (LSTM). *Building of Informatics, Technology and Science (BITS)*, 4(2). <https://doi.org/10.47065/bits.v4i2.2229>
- Alharbi, F. R., & Csala, D. (2022). A Seasonal Autoregressive Integrated Moving Average with Exogenous Factors (SARIMAX) Forecasting Model-Based Time Series Approach. *Inventions*, 7(4), 94. <https://doi.org/10.3390/inventions7040094>
- Arlot, S., & Celisse, A. (2010). A survey of cross-validation procedures for model selection. *Statistics Surveys*, 4(none), 40–79. <https://doi.org/10.1214/09-SS054>
- Avesani, C., Kobuta, I., & Mukhtar, A. (2021). *Enhancing transparency in agrifood trade*. FAO. <https://doi.org/10.4060/cb7210en>
- Blázquez-García, A., Conde, A., Mori, U., & Lozano, J. A. (2020). *A review on outlier/anomaly detection in time series data*.
- Brignoli, P. L., Varacca, A., Gardebroek, C., & Sckokai, P. (2024). Machine learning to predict grains futures prices. *Agricultural Economics*, 55(3), 479–497. <https://doi.org/10.1111/agec.12828>
- Cao, L. J., & Tay, F. E. H. (2003). Support vector machine with adaptive parameters in financial time series forecasting. *IEEE Transactions on Neural Networks*, 14(6), 1506–1518. <https://doi.org/10.1109/TNN.2003.820556>
- Cerqueira, V., Torgo, L., & Mozetič, I. (2020). Evaluating time series forecasting models: an empirical study on performance estimation methods. *Machine Learning*, 109(11), 1997–2028. <https://doi.org/10.1007/s10994-020-05910-7>
- Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Cheng, W., & Li, F. (2025). Analysis of corn price forecast in China based on Lasso-XGBoost-SHAP. *Cogent Food & Agriculture*, 11(1). <https://doi.org/10.1080/23311932.2025.2546076>
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, e623. <https://doi.org/10.7717/peerj-cs.623>
- Das, S., Shukla, S., Kailasam, A. S., Rai, A., Garg, S., & Chakraborti, A. (2026). *Mitigating Financial Risk from Climate-Induced Agricultural Price Volatility*. <https://arxiv.org/abs/2503.24324>
- FAO. (2024). *The State of Food and Agriculture 2024*. FAO. <https://doi.org/10.4060/cd2616en>
- FAO, IFAD, UNICEF, WFP, & WHO. (2024). Technology and innovation: a key enabler for agrifood systems transformation under urbanization. In *The State of Food Security and Nutrition in the World 2024*. FAO; IFAD; UNICEF; WFP; WHO; <https://doi.org/10.4060/cd1254en>

- FAO, & IFPRI. (2023). *La seguridad alimentaria y el comercio agroalimentario en América Latina y el Caribe*. FAO; IFPRI; <https://doi.org/10.4060/cc8592es>
- Goodfellow, Ian., Bengio, Yoshua., & Courville, Aaron. (2017). *Deep learning*. The MIT Press.
- Gu, Y. H., Jin, D., Yin, H., Zheng, R., Piao, X., & Yoo, S. J. (2022). Forecasting Agricultural Commodity Prices Using Dual Input Attention LSTM. *Agriculture (Switzerland)*, 12(2). <https://doi.org/10.3390/agriculture12020256>
- Guindani, L. G., Oliveirai, G. A., Ribeiro, M. H. D. M., Gonzalez, G. V., & de Lima, J. D. (2024). Exploring current trends in agricultural commodities forecasting methods through text mining: Developments in statistical and artificial intelligence methods. *Heliyon*, 10(23). <https://doi.org/https://doi.org/10.1016/j.heliyon.2024.e40568>
- Harshana, P. V. S., & Ratnasiri, S. (2023). Asymmetric price transmission along the supply chain of perishable agricultural commodities: A nonlinear ARDL approach. *The Journal of Economic Asymmetries*, 27. <https://doi.org/10.1016/j.jeca.2023.e00305>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Htun, N.-N., Rojo, D., Ooge, J., De Croon, R., Kasimati, A., & Verbert, K. (2022). Developing Visual-Assisted Decision Support Systems across Diverse Agricultural Use Cases. *Agriculture*, 12(7), 1027. <https://doi.org/10.3390/agriculture12071027>
- Hyndman, R. J., & Athanasopoulos, G. (2021a). ARIMA models. In *Forecasting: principles and practice* (3rd ed.). OTexts: Melbourne. OTexts.com/fpp3
- Hyndman, R. J., & Athanasopoulos, G. (2021b). Evaluating distributional forecast accuracy. In *Forecasting: principles and practice* (3rd ed.). OTexts: Melbourne. OTexts.com/fpp3
- Hyndman, R. J., & Athanasopoulos, G. (2021c). Evaluating point forecast accuracy. In *Forecasting: principles and practice* (3rd ed.). OTexts: Melbourne. OTexts.com/fpp3
- Hyndman, R. J., & Athanasopoulos, G. (2021d). Forecasting: Principles and Practice. In *Forecasting: principles and practice* (3rd ed., Vol. 3rd). OTexts: Melbourne. OTexts.com/fpp3
- Hyndman, R. J., & Athanasopoulos, G. (2021e). Time series decomposition. In *Forecasting: principles and practice* (3rd ed.). OTexts: Melbourne. OTexts.com/fpp3
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
- Indra Sanjaya, F., & Heksaputra, D. (2020). *Prediksi Rerata Harga Beras Tingkat Grosir Indonesia dengan Long Short Term Memory*. 7(2), 163–174. <http://jurnal.mdp.ac.id>
- Jaiswal, R., Jha, G. K., Choudhary, K., & Kumar, R. R. (2022). *STL decomposition based LSTM model for seasonal agricultural price forecasting*. <https://doi.org/10.21203/rs.3.rs-1350423/v1>

- Jaiswal, R., Jha, G. K., Choudhary, K., & Kumar, R. R. (2023). Agricultural Commodity Price Prediction using Long Short-Term Memory (LSTM) based Neural Networks. *Bhartiya Krishi Anusandhan Patrika*, (Of). <https://doi.org/10.18805/BKAP613>
- Krishna, P. A., Narayana, G. V. S., Kotha, S. K., & Pattnayak, D. (2026). Machine Learning Based Agricultural Price Forecasting for Major Food Crops in India Using Environmental and Economic Factors. *The 3rd International Online Conference on Agriculture*, 7. <https://doi.org/10.3390/blsf2025054007>
- Lagarteja, J., & Taracatac, A. (2023). Price Prediction with Bidirectional Long Short-Term Memory Algorithm for High-Value Commercial Crops. *International Journal of Computing Sciences Research*, 7, 1419–1443. <https://doi.org/10.25147/ijcsr.2017.001.1.109>
- Lambert, L. H., Schoeneman, J. P., Lambert, D. M., & Brienens, M. W. (2025). Road networks and food price volatility. *Global Food Security*, 47. <https://doi.org/10.1016/j.gfs.2025.100884>
- MAG. (2019). *2018 - Mapa de ubicación de mercados mayoristas monitoreados por el Ministerio de Agricultura y Ganadería en el Ecuador, escala 1:50.000, año 2018*.
- MAG. (2024). *Resumen de indicadores: Julio 2024. Sistema de Información Pública Agropecuaria*. https://sipa.agricultura.gob.ec/descargas/resumen-indicadores/2024/indicadores_julio_2024.pdf
- MAGP. (2026). *RANGOS DE PRECIOS REFERENCIALES PARA EL CONTROL DE LOS INTENDENTES-DECRETO 14 38*. <https://sipa.agricultura.gob.ec/index.php/precios-referenciales>
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2022). M5 accuracy competition: Results, findings, and conclusions. *International Journal of Forecasting*, 38(4), 1346–1364. <https://doi.org/10.1016/j.ijforecast.2021.11.013>
- Manogna, R. L., Dharmaji, V., & Sarang, S. (2025). Enhancing agricultural commodity price forecasting with deep learning. *Scientific Reports*, 15(1), 20903. <https://doi.org/10.1038/s41598-025-05103-z>
- Min, Y., Kim, Y. R., Hyon, Y., Ha, T., Lee, S., Hyun, J., & Lee, M. R. (2025). RNN and GNN based prediction of agricultural prices with multivariate time series and its short-term fluctuations smoothing effect. *Scientific Reports*, 15(1), 13681. <https://doi.org/10.1038/s41598-025-97724-7>
- Murugesan, R., Mishra, E., & Krishnan, A. H. (2022). Forecasting agricultural commodities prices using deep learning-based models: basic LSTM, bi-LSTM, stacked LSTM, CNN LSTM, and convolutional LSTM. *International Journal of Sustainable Agricultural Management and Informatics*, 8(3), 242. <https://doi.org/10.1504/IJSAMI.2022.125757>
- Mustafa, Z., Vitali, G., Huffaker, R., & Canavari, M. (2024). A systematic review on price volatility in agriculture. *Journal of Economic Surveys*, 38(1), 268–294. <https://doi.org/10.1111/joes.12549>
- Nassar, L., Okwuchi, I. E., Saad, M., Karray, F., & Ponnambalam, K. (2020). Deep Learning Based Approach for Fresh Produce Market Price Prediction. *2020 International Joint*

- Conference on Neural Networks (IJCNN)*, 1–7.
<https://doi.org/10.1109/IJCNN48605.2020.9207537>
- Nayak, G. H. H., Alam, M. W., Singh, K. N., Avinash, G., Kumar, R. R., Ray, M., & Deb, C. K. (2024). Exogenous variable driven deep learning models for improved price forecasting of TOP crops in India. *Scientific Reports*, 14(1), 17203. <https://doi.org/10.1038/s41598-024-68040-3>
- Nguyen, H., Randall, M., & Lewis, A. (2024). Factors Affecting Crop Prices in the Context of Climate Change—A Review. *Agriculture*, 14(1), 135.
<https://doi.org/10.3390/agriculture14010135>
- Noboa, S., Solís, E., & Cuenca, E. (2022). Ecuador Agricultural Product Price Forecast: A Comparative Study of Deep Learning Models. In G. and F. C. E. R. and B.-G. S. Herrera-Tapia Jorge and Rodriguez-Morales (Ed.), *Information and Communication Technologies* (pp. 137–151). Springer International Publishing.
- OECD/FAO. (2024). *OECD-FAO Agricultural Outlook 2024-2033*. OECD Publishing.
<https://doi.org/10.1787/4c5d2cfb-en>
- Ogol, B. O., Omondi, E., Olukuru, J., Muriithi, B., & Senagi, K. (2025). Predicting food prices in Kenya using machine learning: a hybrid model approach with XGBoost and gradient boosting. *Frontiers in Artificial Intelligence*, 8. <https://doi.org/10.3389/frai.2025.1661989>
- Ooge, J., & Verbert, K. (2022). Visually Explaining Uncertain Price Predictions in Agrifood: A User-Centred Case-Study. *Agriculture*, 12(7), 1024.
<https://doi.org/10.3390/agriculture12071024>
- Pan, Z., & Zheng, X. (2023). Price volatility transmission of perishable agricultural products: evidence from China. *Economic Research-Ekonomska Istraživanja*, 36(1).
<https://doi.org/10.1080/1331677X.2023.2180058>
- Paul, R. K., Yeasin, M., Tamilselvi, C., Paul, A. K., Sharma, P., & Birthal, P. S. (2025). Can Deep Learning Models Enhance the Accuracy of Agricultural Price Forecasting? Insights From India. *Intelligent Systems in Accounting, Finance and Management*, 32(1).
<https://doi.org/10.1002/isaf.70002>
- Peña-Holguín, R. R., Vaca-Coronel, C. A., Farías-Lema, R. M., Zapatier-Castro, S. V., & Valenzuela-Cobos, J. D. (2025). Smart Agriculture in Ecuador: Adoption of IoT Technologies by Farmers in Guayas to Improve Agricultural Yields. *Agriculture*, 15(15), 1679.
<https://doi.org/10.3390/agriculture15151679>
- Ray, S., Lama, A., Mishra, P., Biswas, T., Sankar Das, S., & Gurung, B. (2023). An ARIMA-LSTM model for predicting volatile agricultural price series with random forest technique. *Applied Soft Computing*, 149, 110939. <https://doi.org/10.1016/j.asoc.2023.110939>
- Ryu, G.-A., Chuluunsai Khan, T., Nasridinov, A., Rah, H., & Yoo, K.-H. (2023). SCE-LSTM: Sparse Critical Event-Driven LSTM Model with Selective Memorization for Agricultural Time-Series Prediction. *Agriculture*, 13(11), 2044.
<https://doi.org/10.3390/agriculture13112044>

- Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 2(3), 160. <https://doi.org/10.1007/s42979-021-00592-x>
- SIPA. (2025). *Atlas Agroeconómico del Ecuador 2025*.
- SIPA. (2026a). *Estadísticas Económicas*. Ministerio de Agricultura, Ganadería y Pesca. <https://sipa.agricultura.gob.ec/index.php/sipa-estadisticas/estadisticas-descargas/estadisticas-economicas>
- SIPA. (2026b). Índices del sector. In *Estadísticas Económicas*. https://sipa.agricultura.gob.ec/descargas/base-estadistica/modulo_economico/indices-sector.xlsx
- SIPA. (2026c). IPC de alimentos e inflación. In *Estadísticas Económicas*. https://sipa.agricultura.gob.ec/descargas/base-estadistica/modulo_economico/ipc-alimentos-inflacion.xlsx
- SIPA. (2026d). Precios agroquímicos y fertilizantes. In *Estadísticas Económicas*. https://sipa.agricultura.gob.ec/descargas/base-estadistica/modulo_economico/precios-agroquimicos-fertilizantes.xlsx
- SIPA. (2026e). Precios mercados mayoristas y bodegas comerciales. In *Estadísticas Económicas*. https://sipa.agricultura.gob.ec/descargas/base-estadistica/modulo_economico/precios-mercados-mayoristas-bodegas-comerciales.xlsx
- SIPA. (2026f). Precios productor. In *Estadísticas Económicas*. https://sipa.agricultura.gob.ec/descargas/base-estadistica/modulo_economico/precios-productor-ponderado.xlsx
- Sun, C., Pei, M., Cao, B., Chang, S., & Si, H. (2023). A Study on Agricultural Commodity Price Prediction Model Based on Secondary Decomposition and Long Short-Term Memory Network. *Agriculture*, 14(1), 60. <https://doi.org/10.3390/agriculture14010060>
- Sun, F., Meng, X., Zhang, Y., Wang, Y., Jiang, H., & Liu, P. (2023). Agricultural Product Price Forecasting Methods: A Review. *Agriculture*, 13(9). <https://doi.org/10.3390/agriculture13091671>
- Tami, M., & Owda, A. Y. (2024). Efficient commodity price forecasting using long short-term memory model. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 13(1), 994. <https://doi.org/10.11591/ijai.v13.i1.pp994-1004>
- Theofilou, A., Nastis, S. A., Michailidis, A., Bournaris, T., & Mattas, K. (2025). Predicting Prices of Staple Crops Using Machine Learning: A Systematic Review of Studies on Wheat, Corn, and Rice. *Sustainability*, 17(12), 5456. <https://doi.org/10.3390/su17125456>
- Vairo, A., Sgarro, G. A., & Romano, F. (2024). Predicting commodity prices: a neural networks approach to improve market prospects. *Applied Mathematical Sciences*, 18(6), 289–298. <https://doi.org/10.12988/ams.2024.919149>
- Wang, F., Song, G., Xuan, J., & Wu, H. (2021). *Selling Prices Monitoring Model for Agricultural Products Based on LSTM* (pp. 1860–1867). https://doi.org/10.1007/978-3-030-70665-4_201

- Wang, Y., Wu, H., Dong, J., Qin, G., Zhang, H., Liu, Y., Qiu, Y., Wang, J., & Long, M. (2024). *TimeXer: Empowering Transformers for Time Series Forecasting with Exogenous Variables*. <https://arxiv.org/abs/2402.19072>
- Xia, C. (2024). Comparative Analysis of ARIMA and LSTM Models for Agricultural Product Price Forecasting. *Highlights in Science, Engineering and Technology*, 85, 1032–1040. <https://doi.org/10.54097/8q6nx369>
- Yahaya Shehu, Z., Dutse, A. Y., Gital, A. Y., Abdullahi, U. A., & Zahraddeen Yakubu, I. (2024). Improving the Accuracy of Food Commodity Price Prediction Model Using Deep Learning Algorithm. *International Journal of Innovative Science and Research Technology (IJISRT)*, 363–367. <https://doi.org/10.38124/ijisrt/IJISRT24JUN055>
- Yin, H., Jin, D., Gu, Y. H., Park, C. J., Han, S. K., & Yoo, S. J. (2020). STL-ATTLLSTM: Vegetable price forecasting using stl and attention mechanism-based LSTM. *Agriculture (Switzerland)*, 10(12), 1–17. <https://doi.org/10.3390/agriculture10120612>
- Zhang, T., & Tang, Z. (2024). Agricultural commodity futures prices prediction based on a new hybrid forecasting model combining quadratic decomposition technology and LSTM model. *Frontiers in Sustainable Food Systems*, 8. <https://doi.org/10.3389/fsufs.2024.1334098>

Apéndice A. Análisis provincial para Maracuyá

Figura A1

Comparación de precios reales y predichos para Maracuyá en Guayas




Figura A2

Comparación de precios reales y predichos para Maracuyá en Los Ríos




Figura A3

Comparación de precios reales y predichos para Maracuyá en Manabí





Figura A4

Comparación de precios reales y predichos para Maracuyá en Santo Domingo de los Tsáchilas



Apéndice B. Análisis provincial para Papa Superchola

Figura B1

Comparación de precios reales y predichos para Papa Superchola en Pichincha




Figura B2

Comparación de precios reales y predichos para Papa Superchola en Bolívar




Figura B3

Comparación de precios reales y predichos para Papa Superchola en Cañar




Figura B4

Comparación de precios reales y predichos para Papa Superchola en Carchi




Figura B5

Comparación de precios reales y predichos para Papa Superchola en Chimborazo




Figura B6

Comparación de precios reales y predichos para Papa Superchola en Cotopaxi





Figura B7

Comparación de precios reales y predichos para Papa Superchola en Tungurahua



Apéndice C. Análisis provincial para Tomate Riñón de Invernadero

Figura C1

Comparación de precios reales y predichos para Tomate Riñón de Invernadero en Azuay




Figura C2

Comparación de precios reales y predichos para Tomate Riñón de Invernadero en Chimborazo




Figura C3

Comparación de precios reales y predichos para Tomate Riñón de Invernadero en Imbabura





Figura C4

Comparación de precios reales y predichos para Tomate Riñón de Invernadero en Tungurahua



Apéndice D. Repositorios Digitales

El código fuente, los conjuntos de datos procesados, los archivos de configuración, los resultados de entrenamiento, las métricas de evaluación, las predicciones generadas, las visualizaciones, el prototipo web se encuentran disponibles en los siguientes repositorios digitales:

- [Repositorio digital modelado](#)
- [Repositorio digital prototipo web - Back](#)
- [Repositorio digital prototipo web - Front](#)