

*Predicción de Ventas con Machine Learning y Visualización Adaptativa con
Business Intelligence en una Empresa Logística del Ecuador*

*Sales Forecasting with Machine Learning and Adaptive Visualization with Business
Intelligence in an Ecuadorian Logistics Company*

*Previsione delle vendite con Machine Learning e visualizzazione adattiva con
Business Intelligence in un'azienda logistica dell'Ecuador*

Johanna María Achance Solís¹

Email: johanna.achances@ug.edu.ec

ORCID: <https://orcid.org/0009-0000-5720-1063>

Yomira Yamilex Preciado Cortez²

Email: ypreciado@uagraria.edu.ec

ORCID: <https://orcid.org/0009-0007-7852-3185>

Julio Goivanni Litardo Unda³

Email: julio.litardo@ug.edu.ec

ORCID: <https://orcid.org/0009-0008-3931-8151>

Liliam Stephania Garzón Reyes⁴

Email: lgarzon@uagraria.edu.ec

ORCID: <https://orcid.org/0009-0005-3954-4333>

Correspondencia: Johanna María Achance Solís¹ Email: johanna.achances@ug.edu.ec

Artículo de investigación

* **Recibido:** 15-09-2026 * **Aceptado:** 01-10-2026 * **Publicado:** 28-10-2026

1. Facultad de Ingeniería Industrial, Universidad de Guayaquil, Guayaquil, Ecuador.
2. Facultad de Ciencias Agrarias, Universidad Agraria del Ecuador, Guayaquil, Ecuador.
3. Facultad de Ingeniería Industrial, Universidad de Guayaquil, Guayaquil, Ecuador.
4. Facultad de Ciencias Agrarias, Universidad Agraria del Ecuador, Guayaquil, Ecuador.

Resumen

Este estudio aborda el desafío de anticipar la demanda en el sector logístico ecuatoriano mediante la integración de machine learning (ML) con business intelligence (BI) y visualización adaptativa. Usando registros consolidados de ventas mensuales (2019-2025), se entrenaron siete enfoques de pronóstico (Random Forest, Gradient Boosting, Support Vector Regression, k-Nearest Neighbors, Regresión Lineal, Prophet y un modelo base naive estacional) bajo un protocolo idéntico de entrenamiento/prueba cronológico (entrenamiento 2019-2023, prueba sobre 2024) y se evaluaron con MAE, RMSE, MAPE y R^2 . Random Forest obtuvo el mejor desempeño (MAPE = 8.43%), superando al modelo base (11.56%) y superando claramente a los enfoques que extrapolan tendencia, como la Regresión Lineal (32.53%) y Prophet (27.23%). Un análisis de errores detallado, replicado de forma independiente para cada categoría de servicio de negocio, muestra además que los modelos de conjunto basados en árboles presentan un sesgo pequeño y consistente, más fácil de corregir que la varianza impredecible mes a mes del modelo base, que la ventaja agregada de Random Forest está impulsada principalmente por las tres categorías de mayor valor (Paletizado, Flete, Granos), y que los modelos basados en tendencia sobreproyectan sistemáticamente las ventas durante el período atípico y casi estancado de 2024, posterior a una fuerte contracción en 2023. Los pronósticos validados se integraron en tableros de BI adaptativos que exponen vistas a nivel de categoría, zona y ruta con indicadores de incertidumbre. Estos resultados muestran que combinar un modelo de ML rigurosamente validado con tableros adaptativos mejora tanto la precisión del pronóstico como su interpretabilidad para los tomadores de decisiones logísticas, mientras que los análisis comparativo y de errores aportan un protocolo de evaluación reproducible para estudios de predicción de ventas en el sector logístico latinoamericano.

Palabras clave: Predicción de Ventas, Machine Learning, Business Intelligence, Evaluación de Modelos, Visualización Adaptativa.

Abstract

This study addresses the challenge of anticipating demand in the Ecuadorian logistics sector by integrating machine learning (ML) with business intelligence (BI) and adaptive visualization. Using consolidated monthly sales records (2019-2025), seven forecasting approaches (Random Forest, Gradient Boosting, Support Vector Regression, k-Nearest Neighbors, Linear Regression, Prophet, and a seasonal naive baseline) were trained under an identical chronological train/test protocol (training 2019-2023, testing on 2024) and evaluated with MAE, RMSE, MAPE, and R^2 . Random Forest achieved the best performance (MAPE = 8.43%), outperforming the baseline (11.56%) and clearly surpassing trend-extrapolating approaches such as Linear Regression (32.53%) and Prophet (27.23%). A detailed error analysis, independently replicated for each business service category, further shows that tree-based ensemble models exhibit a small and consistent bias, easier to correct than the unpredictable

month-to-month variance of the baseline; that the aggregate advantage of Random Forest is driven mainly by the three highest-value categories (Palletizing, Freight, Grains); and that trend-based models systematically overproject sales during the atypical, nearly stagnant 2024 period that followed a sharp contraction in 2023. The validated forecasts were integrated into adaptive BI dashboards that expose category-, zone-, and route-level views with uncertainty indicators. These results show that combining a rigorously validated ML model with adaptive dashboards improves both forecast accuracy and its interpretability for logistics decision-makers, while the comparative and error analyses provide a reproducible evaluation protocol for sales forecasting studies in the Latin American logistics sector.

Keywords: Sales forecasting, Machine Learning, Business Intelligence, Model evaluation, Adaptive visualization.

Riassunto

Questo studio affronta la sfida di anticipare la domanda nel settore logistico ecuadoriano integrando il machine learning (ML) con la business intelligence (BI) e la visualizzazione adattiva. Utilizzando registri consolidati delle vendite mensili (2019-2025), sono stati addestrati sette approcci previsionali (Random Forest, Gradient Boosting, Support Vector Regression, k-Nearest Neighbors, Regressione Lineare, Prophet e un modello di base naive stagionale) secondo un identico protocollo cronologico di addestramento/test (addestramento 2019-2023, test sul 2024) e sono stati valutati con MAE, RMSE, MAPE e R^2 . Random Forest ha ottenuto le prestazioni migliori (MAPE = 8,43%), superando il modello di base (11,56%) e superando nettamente gli approcci che estrapolano la tendenza, come la Regressione Lineare (32,53%) e Prophet (27,23%). Un'analisi dettagliata degli errori, replicata in modo indipendente per ciascuna categoria di servizio, mostra inoltre che i modelli di insieme basati su alberi presentano una distorsione piccola e costante, più facile da correggere della varianza imprevedibile mese per mese del modello di base; che il vantaggio aggregato di Random Forest è determinato principalmente dalle tre categorie di maggior valore (Pallettizzazione, Nolo, Cereali); e che i modelli basati sulla tendenza sovrastimano sistematicamente le vendite durante il periodo atipico e quasi stagnante del 2024, successivo a una forte contrazione nel 2023. Le previsioni convalidate sono state integrate in cruscotti di BI adattivi che mostrano viste per categoria, zona e percorso con indicatori di incertezza. Questi risultati mostrano che combinare un modello di ML rigorosamente convalidato con cruscotti adattivi migliora sia l'accuratezza della previsione sia la sua interpretabilità per i decisori logistici, mentre le analisi comparative e degli errori forniscono un protocollo di valutazione riproducibile per gli studi di previsione delle vendite nel settore logistico latinoamericano.

Parole chiave: Previsione delle vendite, Machine Learning, Business Intelligence, Valutazione dei modelli, Visualizzazione adattiva.

1. Introducción

Las empresas logísticas en Ecuador enfrentan desafíos crecientes para anticipar la demanda y planificar recursos de manera eficiente. La evolución de la Business Intelligence (BI) ahora permite combinar visualización interactiva de datos con algoritmos de machine learning (ML), lo que permite a los tomadores de decisiones anticipar el comportamiento de las ventas logísticas con mayor precisión (Choi et al., 2018).

En el contexto logístico ecuatoriano, la mayoría de las empresas usan sistemas de BI principalmente con fines descriptivos, lo que limita su capacidad de anticipar fluctuaciones de la demanda. Aunque se dispone de datos históricos valiosos sobre ventas, entregas y clientes, estos no se aprovechan completamente para generar predicciones que respalden decisiones estratégicas; además, los modelos predictivos existentes rara vez se evalúan con métricas de error estándar ni se integran en herramientas visuales fáciles de interpretar para los tomadores de decisiones.

Este trabajo tiene como objetivo determinar si, y bajo qué condiciones, los enfoques de pronóstico de machine learning mejoran de manera significativa un modelo base naive estacional para una empresa logística ecuatoriana, e integrar los pronósticos validados resultantes en tableros de BI adaptativos. En lugar de asumir que un algoritmo determinado superará al modelo base, Random Forest y Prophet se tratan como candidatos en competencia que deben aceptarse o rechazarse con base en un protocolo de evaluación explícito y reproducible. Los objetivos específicos son: (1) construir un conjunto de datos histórico consolidado de ventas (2019-2025); (2) entrenar y validar modelos de pronóstico de ML, junto con un modelo base naive, bajo un protocolo de evaluación reproducible usando MAE, RMSE, MAPE y R^2 , conservando únicamente el o los enfoques que superen demostrablemente al modelo base; (3) diseñar tableros adaptativos que expongan los pronósticos resultantes por categoría, zona y ruta; y (4) discutir las implicaciones operativas de los pronósticos validados, incluyendo las consecuencias prácticas de que un algoritmo no logre superar al modelo base, para la toma de decisiones logísticas.

El resto de este artículo se organiza de la siguiente manera. La Sección 2 revisa los trabajos relacionados sobre predicción de ventas con ML y visualización adaptativa de BI. La Sección 3 describe los datos, el marco teórico y el protocolo de evaluación. La Sección 4 reporta los resultados de los pronósticos y las métricas de error comparativas. La Sección 5 discute los hallazgos a la luz de los trabajos relacionados, y la Sección 6 presenta las conclusiones y el trabajo futuro.

2. Trabajos Relacionados

Los métodos de conjunto (ensemble) y afines han mostrado un desempeño sólido en la predicción de ventas bajo condiciones no lineales o ruidosas. Mitra et al. (2022) combinaron gradient boosting con otros algoritmos para la predicción de demanda minorista multicanal,

mientras que la formulación original de Breiman (2001) sustenta la mayoría de las aplicaciones de conjuntos basados en árboles. Bi et al. (2022) mostraron que los enfoques de factorización tensorial construidos sobre datos transaccionales a gran escala pueden superar a las líneas base clásicas en entornos minoristas. Más recientemente, Hobor et al. (2026) y Zubair et al. (2024) compararon varios algoritmos modernos de ML para la predicción de ventas minoristas, encontrando de forma consistente que los conjuntos basados en árboles se encuentran entre los de mejor desempeño.

En cuanto a los modelos de series temporales descomponibles, Taylor y Letham (2018) introdujeron Prophet como un procedimiento de pronóstico que maneja la estacionalidad y los cambios de tendencia con un ajuste manual mínimo; Žunić et al. (2020) aplicaron posteriormente Prophet a datos reales de ventas, reportando resultados estables y computacionalmente eficientes. Esto motiva una comparación explícita de modelos basada en métricas, en lugar de depender de una única configuración por defecto, ya que ningún modelo de pronóstico garantiza dominar en todos los horizontes de predicción.

Otros estudios han aplicado ML a problemas relacionados de logística y pronóstico de demanda: Pasupuleti et al. (2024) aplicaron técnicas de optimización de machine learning al pronóstico de demanda en logística y gestión de inventarios, y Goel et al. (2024) revisaron de manera similar las prácticas de pronóstico de demanda en distintos contextos de gestión de cadena de suministro. Ganguly y Mukherjee (2024) mostraron además que los modelos de ML con hiperparámetros optimizados mejoran la precisión del pronóstico de ventas minoristas frente a configuraciones por defecto. Sohrabpour et al. (2021) reportaron un buen ajuste utilizando inteligencia artificial para el pronóstico de ventas de exportación, lo que ilustra el rango de desempeño reportado entre distintos algoritmos y conjuntos de datos.

En cuanto a la visualización, Friendly (2008) traza el desarrollo histórico de la visualización de datos como disciplina de apoyo a la decisión, una base para los tableros adaptativos y sensibles al contexto adoptados en este estudio. Para interpretar las predicciones del modelo para usuarios no técnicos, métodos de explicación como LIME (Ribeiro et al., 2016) ofrecen un mecanismo complementario a los tableros adaptativos para comunicar por qué un modelo produjo un pronóstico determinado.

A pesar de este cuerpo de trabajo, la mayoría de los estudios de pronóstico de ventas aplicados a la logística ecuatoriana o latinoamericana omiten un protocolo explícito de entrenamiento/prueba y una comparación con un modelo base, o no reportan un conjunto completo de métricas de error complementarias (MAE, RMSE, MAPE, R^2) de forma comparativa para los algoritmos evaluados. Aplicaciones ecuatorianas recientes de Random Forest al pronóstico de ventas (Cuesta Astudillo et al., 2024) y estudios comparativos regionales entre algoritmos tradicionales y de ML para pronóstico de demanda (Culcay et al., 2024) confirman un interés local creciente, pero, en línea con el patrón bibliométrico más amplio reportado para Ecuador (Herrera-Franco et al., 2021; Rodríguez et al., 2022; Sisa et al., 2024),

aún no reportan esta combinación. Esta brecha motiva el protocolo de evaluación adoptado en la Sección 3.3, diseñado para hacer plenamente reproducible la comparación entre Random Forest, Prophet y un modelo base naive.

3. Metodología

Se trata de un estudio cuantitativo, aplicado, cuasiexperimental, de alcance predictivo y longitudinal: los datos históricos de ventas se usan para entrenar modelos de pronóstico cuyas salidas luego se contrastan contra períodos reservados y no vistos, en lugar de contra los propios datos de entrenamiento.

3.1 Marco Teórico

El Machine Learning (ML) permite a los sistemas aprender de los datos y generar predicciones sin ser reprogramados explícitamente para cada tarea (Shmueli et al., 2020); la regresión, los conjuntos de árboles de decisión y las redes neuronales son las familias más aplicadas al pronóstico de ventas (Punia et al., 2020; Joseph & Tackes, 2024). La Business Intelligence (BI) se refiere a las tecnologías utilizadas para recopilar, almacenar y analizar datos empresariales que respaldan decisiones (Choi et al., 2018); la visualización adaptativa, en particular, ajusta dinámicamente las representaciones gráficas al contexto del usuario o al tipo de datos analizados, lo cual es especialmente relevante cuando los tomadores de decisiones no técnicos deben interpretar la salida del modelo de ML.

3.2 Datos y Variables

La población comprende todos los registros de ventas generados por la empresa entre 2019 y 2025. La variable dependiente es el valor total de ventas (Vta); las variables independientes describen al cliente, el tipo de servicio de negocio, la propiedad del activo, la zona de operación, la ruta, el tipo de operación, las horas de viaje, la capacidad de carga, la distancia y los términos de crédito, como se resume en la Tabla 1.

Tabla 1. Variables del estudio.

Variable	Código	Descripción
Ventas (dependiente)	Vta	Valor de venta
Cliente	Cli	Parte que contrata el servicio logístico
Tipo de servicio de negocio	Stn	Tipo de servicio por configuración de arrastre de activo
Tipo de propiedad	Tp	Activo propio o de terceros
Zona	Zon	Área geográfica de operación
Ruta	Rut	Ruta de transporte/distribución
Operación	Opr	Tipo de operación logística
Horas de viaje	Hrv	Horas de viaje/transporte
Capacidad de carga (t)	Cp	Capacidad de carga del activo en toneladas
Distancia (km)	Km	Distancia recorrida en la ruta
Días de crédito	Dcr	Plazo de crédito otorgado a los clientes

3.3 Protocolo de Evaluación

Para subsanar la falta de un protocolo de validación explícito identificado en la Sección 2, la serie mensual agregada de ventas (2019-01 a 2024-12, $n = 72$ meses) se dividió cronológicamente: los 60 meses de enero de 2019 a diciembre de 2023 se usaron para entrenamiento, y el año completo 2024 (12 meses) se reservó como período de prueba. Al ser la división cronológica, ambos modelos se evalúan exclusivamente sobre períodos de ventas que no vieron durante el entrenamiento.

Random Forest y Prophet se compararon contra un modelo base naive estacional que repite el valor de cada período a partir del mismo período un año antes; este modelo base representa el pronóstico que obtendría un tomador de decisiones sin ningún modelo de ML y constituye el umbral mínimo que los algoritmos evaluados deben superar para justificar su complejidad adicional.

Se calcularon cuatro métricas de error complementarias sobre el período de prueba para cada modelo: el Error Absoluto Medio (MAE), la Raíz del Error Cuadrático Medio (RMSE), el Error Porcentual Absoluto Medio (MAPE) y el coeficiente de determinación (R^2). El MAE y el RMSE se reportan en las mismas unidades que las ventas (USD), el MAPE se reporta como porcentaje para facilitar la comparación entre categorías de distinta magnitud, y el R^2 indica la proporción de la varianza de las ventas explicada por cada modelo. Valores más bajos de MAE/RMSE/MAPE y más altos de R^2 indican un mejor ajuste.

4. Resultados

Esta sección reporta (i) las métricas de error comparativas obtenidas bajo el protocolo de evaluación descrito en la Sección 3.3, y (ii) los pronósticos de ventas resultantes por categoría de servicio de negocio, junto con su integración en los tableros de BI adaptativos.

4.1 Métricas de Validación del Modelo

Para ir más allá de comparar solo dos algoritmos por defecto, se entrenaron cinco enfoques adicionales de machine learning bajo el protocolo idéntico descrito en la Sección 3.3 — las mismas características diseñadas (índice temporal, mes calendario, rezago de 12 meses) y la misma división cronológica 2019-2023/2024 — junto a Random Forest, Prophet y el modelo base naive estacional: Regresión Lineal, Gradient Boosting, Support Vector Regression (kernel RBF) y k-Nearest Neighbors ($k = 3$). La Tabla 2 reporta MAE, RMSE, MAPE y R^2 para los siete enfoques, ordenados de mejor a peor según el MAPE.

Tabla 2. Métricas de error comparativas de siete enfoques de pronóstico sobre el período de prueba de 2024 (entrenados con ventas mensuales 2019–2023), ordenadas por MAPE.

Modelo	MAE (USD)	RMSE (USD)	MAPE (%)	R^2
Random Forest	61,212	74,071	8.43%	-0.93
Gradient Boosting	75,831	83,418	10.40%	-1.45
SVR (RBF kernel)	76,945	86,664	10.80%	-1.64
k-NN ($k = 3$)	79,294	89,673	11.37%	-1.83
Modelo base naive estacional	81,430	93,647	11.56%	-2.08
Prophet	191,865	197,417	27.23%	-12.71
Linear Regression	228,750	235,597	32.53%	-18.52

Random Forest fue el modelo con mejor desempeño en general (MAPE = 8.43%), seguido por Gradient Boosting (10.40%), SVR (10.80%) y k-NN (11.37%) — los cuatro modelos basados en árboles, kernel e instancias superaron al modelo base naive estacional (11.56%). La Regresión Lineal y Prophet, los dos modelos que dependen de un componente de tendencia explícito y suave, tuvieron un desempeño marcadamente peor que el modelo base (32.53% y 27.23% de MAPE respectivamente). Todos los modelos produjeron un R^2 negativo en este año de prueba, siendo el caso más severo la Regresión Lineal ($R^2 = -18.52$): 2024 fue un período atípico, casi estancado (-0.1% de crecimiento interanual) inmediatamente después de una fuerte contracción del 14.7% en 2023, y los modelos que extrapolan una tendencia continua parecen haber proyectado el patrón de crecimiento previo a 2024 de forma más agresiva que los modelos basados en características rezagadas o locales, amplificando su error ante esta ruptura estructural particular (véase la Sección 4.3 para un análisis de errores detallado).

4.2 Análisis de Errores

Más allá de las métricas de error agregadas, el signo y la dispersión de los residuos mensuales (ventas reales menos predichas) revelan diferencias sistemáticas entre familias de modelos en el período de prueba de 2024. La Tabla 3 reporta, para cada modelo, el residuo medio (sesgo), su desviación estándar, y el mayor error absoluto individual junto con el mes en que ocurrió.

Tabla 3. Sesgo, dispersión y mayor error de los residuos por modelo, período de prueba de 2024.

Modelo	Sesgo (USD)	Desv. est. (USD)	Máx. error (USD)	Mes más difícil
Random Forest	+43,779	59,748	114,271	Mayo 2024
Gradient Boosting	+58,952	59,018	142,478	Mayo 2024
SVR (RBF kernel)	+34,633	79,443	134,181	Feb. 2024
k-NN (k = 3)	-5,564	89,500	156,541	Feb. 2024
Modelo base naive estacional	-608	93,645	171,480	Feb. 2024
Linear Regression	-228,750	56,386	326,589	Feb. 2024

Surgen dos patrones de error distintos. La Regresión Lineal muestra un sesgo negativo muy grande y consistente (−228,750 USD): sobreestima las ventas sistemáticamente cada mes, porque una única tendencia lineal global ajustada sobre 2019-2023 proyecta el crecimiento preexistente hacia 2024 sin ajustarse a la desaceleración; su desviación estándar residual es comparativamente pequeña, lo que significa que el error es consistente en lugar de errático — un signo clásico de una tendencia mal especificada más que de predicciones ruidosas. La propia descomposición de Prophet (Sección 4.1) está sujeta a la misma limitación estructural. El modelo base naive y k-NN, en cambio, muestran casi ningún sesgo promedio pero la mayor dispersión (desv. est. ≈ 90,000-94,000 USD), ya que ambos simplemente reutilizan una observación pasada y por lo tanto siguen el ruido mes a mes en lugar de cualquier cambio estructural.

Random Forest y Gradient Boosting se ubican entre estos dos extremos: ambos muestran un sesgo moderado y positivo (subestiman levemente, en 43,779 y 58,952 USD en promedio respectivamente) con una desviación estándar cercana a la de la Regresión Lineal y notablemente menor que la del modelo base naive. Un sesgo pequeño y consistente es, en la práctica, más fácil de corregir — por ejemplo con un término de recalibración aditivo simple o un reentrenamiento periódico — que las variaciones impredecibles mes a mes del modelo base naive, lo cual es una de las razones por las que Random Forest sigue siendo el modelo preferido en la Sección 4.1 a pesar de su propio R^2 negativo en este año atípico.


Febrero, junio y agosto de 2024 concentran los mayores errores absolutos entre los modelos a nivel agregado (Tabla 3), lo cual sugería un efecto específico de categoría. Desagregar la evaluación por categoría de servicio de negocio confirma esto directamente (Sección 4.3,

Tabla 5): el error agregado no se distribuye de manera uniforme entre categorías, y la ventaja general de Random Forest sobre el modelo base naive proviene casi en su totalidad de las tres categorías de mayor valor.

4.3 Pronósticos de Ventas por Categoría de Servicio de Negocio

Aplicando Random Forest, las ventas históricas (2019-2025) se agruparon en cinco categorías de negocio: Contenedores, Flete, Gas y Combustible, Granos y Paletizado. La Fig. 1 muestra la evolución histórica y la proyección 2026 de las ventas anuales totales por categoría.

Figura 1. Ventas anuales totales por categoría de servicio de negocio (2019-2026), Random Forest.



El eje X representa los años y el eje Y las ventas totales; cada color identifica un tipo de servicio de negocio. Paletizado y Granos concentran la mayor parte del ingreso total. La Tabla 4 resume las ventas anuales totales y el crecimiento interanual bajo Random Forest.

Tabla 4. Ventas anuales totales y crecimiento, Random Forest.

Año	Ventas Totales (USD)	Crecimiento Interanual	Notas
2019	6.1 M	—	Año base
2020	5.9 M	-2.2%	Leve contracción
2021	8.8 M	+47.5%	Fuerte recuperación tras 2020
2022	10.1 M	+15.5%	Crecimiento sostenido, más moderado
2023	8.6 M	-14.7%	Contracción significativa
2024	8.6 M	-0.1%	Estancamiento
2025	11.1 M	+28.2%	Reaceleración
2026 (pronóstico)	11.7 M	+5.5%	Crecimiento sostenido moderado

Dado que la Fig. 1 reporta los pronósticos de Random Forest a nivel de categoría de servicio de negocio, el protocolo de evaluación de la Sección 3.3 se repitió de forma independiente para cada una de las cinco categorías (misma división cronológica 2019-2023/2024, mismas características diseñadas), en lugar de aplicarse únicamente a la serie agregada usada en la Sección 4.1. Esto cierra la brecha entre las métricas de validación agregadas y los pronósticos a nivel de categoría mostrados en esta sección: la Tabla 5 reporta MAE, RMSE, MAPE y R^2 para Random Forest frente al modelo base naive específico de cada categoría.


Tabla 5. Random Forest vs. modelo base naive, validado de forma independiente por categoría de servicio de negocio (prueba 2024).

Categoría	Modelo	MAE (USD)	RMSE (USD)	MAPE (%)	R^2
Contenedores	Naive	23,551	29,919	25.90%	-0.16
Contenedores	Random Forest	29,574	39,016	33.27%	-0.97
Flete	Naive	31,874	40,545	22.04%	-9.28
Flete	Random Forest	20,950	27,954	14.50%	-3.89
Gas y Combustible	Naive	7,029	10,001	109.51%	-0.02
Gas y Combustible	Random Forest	8,878	10,803	124.03%	-0.19
Granos	Naive	56,415	68,982	26.42%	-1.04
Granos	Random Forest	50,870	60,519	20.98%	-0.57
Paletizado	Naive	63,791	73,889	27.43%	-7.55
Paletizado	Random Forest	26,146	30,138	11.39%	-0.42

El desglose a nivel de categoría revela que la mejora agregada reportada en la Sección 4.1 no es uniforme. Random Forest supera claramente al modelo base naive en Paletizado (MAPE 11.39% vs. 27.43%), Flete (14.50% vs. 22.04%) y, de forma más modesta, Granos (20.98% vs. 26.42%) — precisamente las tres categorías de mayor valor, lo que explica la mayor parte de la ganancia agregada. En Contenedores, Random Forest es peor que el modelo base naive (33.27% vs. 25.90%), y en Gas y Combustible — la categoría más pequeña y errática, con un MAPE superior al 100% en ambos modelos — ningún enfoque es confiable, y el modelo base naive es marginalmente preferible a Random Forest. Esto indica que la elección del modelo debería hacerse por categoría en lugar de asumir que un único algoritmo es uniformemente el mejor, y que Gas y Combustible en particular se beneficiaría de un tratamiento dedicado (por ejemplo, un modelo de demanda intermitente) en lugar de las mismas características de rezago/estacionalidad usadas para las categorías de mayor volumen.

Al aplicar Prophet a las mismas categorías (Fig. 2) se obtiene un patrón de crecimiento comparable, cerrando con un incremento anual esperado del 5.2% y \$11.2M en ventas totales para 2026 — los dos modelos coinciden por lo tanto cualitativamente, y la Tabla 2 anterior cuantifica cuál de ellos se ajusta más de cerca a los datos de prueba.

Figura 2. Ventas anuales totales por categoría de servicio de negocio (2019-2026), Prophet.



5. Discusión

La comparación de siete enfoques de pronóstico (Sección 4.1) indica que la familia del modelo importa más que la sofisticación algorítmica para este conjunto de datos: los conjuntos basados en árboles (Random Forest, Gradient Boosting) y los modelos basados en kernel/instancias (SVR, k-NN) superaron todos al modelo base naive estacional, mientras que ambos enfoques que extrapolan tendencia (Regresión Lineal, Prophet) tuvieron un desempeño marcadamente peor que ese mismo modelo base. Esto sugiere que, para una serie volátil y con cambios estructurales como esta, los modelos que dependen de información local/rezagada se adaptan mejor a una desaceleración abrupta que los modelos que proyectan una única tendencia global hacia adelante, lo cual constituye la lección metodológica central de este estudio.

Random Forest mostró un comportamiento cíclico, comparativamente estable, con fases de crecimiento en 2021-2022, una leve contracción en 2023 y una recuperación hacia 2026; esto coincide con Pavlyshenko (2019), quien encontró que los métodos de conjunto capturan bien las fluctuaciones del mercado incluso bajo irregularidades estacionales. En la evaluación cuantitativa 2024 (Sección 4.1), Random Forest fue también el ganador cuantitativo claro, mientras que Prophet sobreproyectó sustancialmente el crecimiento durante el periodo atípico de 2024 (MAPE = 27.23%, $R^2 = -12.71$), con un desempeño inferior incluso al del modelo base naive. Esto contrasta con reportes previos de desempeño estable de Prophet bajo estacionalidad

regular (Žunić et al., 2020) e ilustra un riesgo más amplio: ningún modelo de pronóstico domina en todos los periodos, y el buen ajuste de un modelo bajo condiciones normales no garantiza robustez frente a quiebres estructurales abruptos como la contracción de 2023 observada aquí.

Paletizado y Granos concentraron la mayor parte de las ventas totales, confirmando su rol estratégico en la cadena logística, en línea con Pasupuleti et al. (2024), quienes vincularon las líneas de negocio de alto volumen con una correlación más fuerte entre precisión de pronóstico y rentabilidad. Gas y Combustible mostró una participación menor y más volátil, sensible a factores externos como los precios internacionales del petróleo; en línea con esta volatilidad, la validación por categoría de la Sección 4.3 (Tabla 5) encontró que Random Forest no ofrece ninguna ventaja sobre el modelo base naive específicamente para Gas y Combustible, mientras que entrega sus mayores mejoras para Paletizado y Flete, las dos categorías más estables y de mayor valor.

Desde una perspectiva de apoyo a la decisión, integrar los pronósticos validados en tableros de BI adaptativos tradujo la salida del modelo en señales accionables por categoría, zona y ruta, reforzando el valor de la visualización adaptativa para reducir la dependencia técnica de los usuarios de negocio. En comparación con la literatura revisada, la principal contribución metodológica de este trabajo respecto a la versión inicial del estudio es el protocolo explícito de evaluación entrenamiento/prueba y el modelo base naive, que permiten atribuir las mejoras reportadas a los propios modelos y no a un ajuste dentro de muestra no validado.

6. Conclusiones y Trabajo Futuro

Consolidar los registros históricos y generados por el sistema de ventas en un único repositorio depurado produjo un conjunto de datos coherente y trazable que respalda un análisis descriptivo confiable y un modelado predictivo. Bajo una comparación controlada de siete enfoques de pronóstico sobre un período de prueba cronológico de 2024, Random Forest fue el modelo claramente preferido ($MAE = 61,212$, $MAPE = 8.43\%$, superando al modelo base naive de 11.56% y a todos los demás modelos evaluados), mientras que los enfoques que extrapolan tendencia (Regresión Lineal, Prophet) rindieron por debajo incluso del modelo base naive en este año atípico y casi estancado. Esto aporta evidencia cuantitativa y reproducible — incluyendo un análisis de errores a nivel de sesgo/varianza, no solo precisión agregada — para respaldar la adopción de Random Forest en este conjunto de datos, con la salvedad importante, confirmada por la validación a nivel de categoría en la Sección 4.3, de que esta ventaja se concentra en las categorías de mayor valor y no se extiende al segmento más pequeño y errático de Gas y Combustible.

Los tableros de BI adaptativos tradujeron la salida del modelo en señales accionables para decisiones a nivel de categoría, zona y ruta, incorporando indicadores de incertidumbre y métricas clave; esto redujo la dependencia técnica de los usuarios de negocio y aceleró el ciclo de análisis a decisión.

Como trabajo futuro, recomendamos: (i) extender el protocolo de evaluación con validación cruzada de series temporales (por ejemplo, walk-forward validation) a través de múltiples horizontes de pronóstico en lugar de una única división entrenamiento/prueba; (ii) ampliar la comparación a modelos adicionales no cubiertos aquí (por ejemplo, ARIMA, XGBoost, LSTM) y desarrollar una selección de modelo específica por categoría — por ejemplo, un modelo de demanda intermitente o basado en conteos para Gas y Combustible, donde Random Forest actualmente no ofrece ningún beneficio sobre el modelo base naive; (iii) establecer un marco formal de gobernanza de datos (diccionario de datos, reglas de validación, trazabilidad de linaje) para sostener la calidad de los datos a medida que se incorporan nuevas fuentes; y (iv) operar un ciclo formal de reentrenamiento y monitoreo de deriva del modelo, de modo que MAE/RMSE/MAPE/R² se recalculen periódicamente y se usen como disparadores de recalibración en producción.

Referencias

- Bi, X., Adomavicius, G., Li, W., Qu, A.: Improving sales forecasting accuracy: a tensor factorization approach with demand awareness. *INFORMS Journal on Computing* 34(3), 1644–1660 (2022)
- Breiman, L.: Random forests. *Machine Learning* 45(1), 5–32 (2001)
- Choi, T.M., Wallace, S.W., Wang, Y.: Big data analytics in operations management. *Production and Operations Management* 27(10), 1868–1883 (2018)
- Chopra, S., Meindl, P.: *Supply Chain Management*. Pearson (2020)
- Cuesta Astudillo, F.L., Buele Nugra, I.G., Coral Pesantez, L.E., Marin Neira, D.M.: Pronóstico de ventas en empresas manufactureras ecuatorianas aplicando Random Forest. In: XI Congreso Internacional de Auditoría, Gestión y Negocios (CIAGEN 2024), Ecuador (2024)
- Culcay, L., Bustillos, F., Vallejo-Huanga, D.: Home appliance demand forecasting: a comparative approach using traditional and machine learning algorithms. In: Arai, K. (ed.) *Intelligent Systems and Applications (IntelliSys 2023)*, vol. 3. LNNS, vol. 824, pp. 457–473. Springer (2024)
- Efat, M.I.A., Hajek, P., Abedin, M.Z., Azad, R.U., Al Jaber, M., Aditya, S., Hassan, M.K.: Deep-learning model using hybrid adaptive trend estimated series for modelling and forecasting sales. *Annals of Operations Research* 339, 297–328 (2024)
- Friendly, M.: A brief history of data visualization. In: Chen, C.H., Härdle, W., Unwin, A. (eds.) *Handbook of Data Visualization*, pp. 15–56. Springer (2008)
- Ganguly, P., Mukherjee, I.: Enhancing retail sales forecasting with optimized machine learning models. In: 2024 International Conference on Smart Electronics and Systems (ICSSES). IEEE (2024)
- Goel, L., Nandal, N., Gupta, S., Karanam, M., Yeluri, L.P., Pandey, A.K., Rozhdestvenskiy, O.I., Grabovy, P.: Revealing the dynamics of demand forecasting in supply chain management: a holistic investigation. *Cogent Engineering* 11(1) (2024)
- Herrera-Franco, G., Montalván-Burbano, N., Mora-Frank, C., Bravo-Montero, L.: Scientific research in Ecuador: a bibliometric analysis. *Publications* 9(4), 55 (2021)
- Hobor, L., Brčić, M., Polutnik, L., Kapetanović, A.: Comparative analysis of modern machine learning models for retail sales forecasting. *Croatian Operational Research Review* 17(2), 285–296 (2026)

- Joseph, M., Tackes, J.: *Modern Time Series Forecasting with Python: Industry-Ready Machine Learning and Deep Learning Time Series Analysis with PyTorch and pandas*, 2nd edn. Packt Publishing (2024)
- Ma, S., Fildes, R.: Retail sales forecasting with meta-learning. *European Journal of Operational Research* 288(1), 111–128 (2021)
- Mitra, A., Jain, A., Kishore, A., Kumar, P.: A comparative study of demand forecasting models for a multi-channel retail company: a novel hybrid machine learning approach. *SN Operations Research Forum* 3(4), 1–22 (2022)
- Pasupuleti, V., Thuraka, B., Kodete, C.S., Malisetty, S.: Enhancing supply chain agility and sustainability through machine learning: optimization techniques for logistics and inventory management. *Logistics* 8(3), 73 (2024)
- Pavlyshenko, B.M.: Machine-learning models for sales time series forecasting. *Data* 4(1), 15 (2019)
- Punia, S., Nikolopoulos, K., Singh, S.P., Madaan, J.K., Litsiou, K.: Deep learning with LSTM networks and random forests for demand forecasting in multi-channel retail. *International Journal of Production Research* 58(16), 4964–4979 (2020)
- Ribeiro, M.T., Singh, S., Guestrin, C.: “Why should I trust you?” Explaining the predictions of any classifier. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 1135–1144. ACM (2016)
- Rodríguez, V., Flores-Sanchez, M., Zambrano, C.H., Rincón, L., Paz, J.L., Torres, F.J.: Analysis of Ecuador’s SCOPUS scientific production during the 2001–2020 period by means of standardized citation indicators. *Heliyon* 8(4), e09329 (2022)
- Shmueli, G., Bruce, P.C., Gedeck, P., Patel, N.R.: *Data Mining for Business Analytics: Concepts, Techniques, and Applications in Python*. Wiley (2020)
- Sisa, I., Caicedo-Potosí, J., Cordovez, M., Verdezoto, C., Barreno, M., Coral, M., Herrera-Franco, G.: One hundred years of Ecuadorian biomedical scientific output and its association with the main causes of mortality: a bibliometric study. *Frontiers in Medicine* 11, 1395433 (2024)
- Sohrabpour, V., Oghazi, P., Toorajipour, R., Nazarpour, A.: Export sales forecasting using artificial intelligence. *Technological Forecasting and Social Change* 163, 120480 (2021)
- Taylor, S.J., Letham, B.: Forecasting at scale. *The American Statistician* 72(1), 37–45 (2018)
- Žunić, E., Korjenić, K., Hodžić, K., Đonko, D.: Application of Facebook’s Prophet algorithm for successful sales forecasting based on real-world data. *International Journal of Computer Science & Information Technology* 12(2), 23–36 (2020)
- Zubair, M., Waleed, A., Rehman, A., Ahmad, F., Islam, M., Javed, S.: Machine learning insights into retail sales prediction: a comparative analysis of algorithms. In: *2024 International Conference on Horizons of Information Technology and Engineering (HITE)*. IEEE (2024)