

UNIVERSIDAD MAYOR DE SAN ANDRÉS
FACULTAD DE INGENIERÍA
CARRERA DE INGENIERÍA INDUSTRIAL



REVISTA INDUSTRIAL 4.0

ISSN-L 2958-0188
JUNIO 2026

Nro.
13
EDICIÓN
DIGITAL

INDEXADA AL DIALNET



UNIVERSIDAD MAYOR DE SAN ANDRÉS
FACULTAD DE INGENIERÍA
CARRERA DE INGENIERÍA INDUSTRIAL

Maria Eugenia García Moreno Ph. D.
Dr. Tito V. Estevez Martini
M.Sc. Ing. Miguel Angel Calla Carrasco
M.Sc. Ing. Marcelo Ramirez Molina
Mg. Ing. Aldo Felipe Vargas Pacheco

Rector
Vicerrector
Decano Facultad de Ingeniería
ViceDecano Facultad de Ingeniería
Director de Carrera Ingeniería Industrial

Revista Industrial 4.0
Edición impresa N°13 Junio 2026

Comite Editor:

M.Sc. Ing. Fernando Sanabria Camacho
Ing. Mario Zenteno Benitez PhD.
Ing. Oswaldo Terán Modragón PhD.
Ing. Mónica Lino Humerez PhD.
Ing. Franz Zenteno Benitez PhD.

Diseño Versión Impresa & Web:
Ing. Enrique Orosco Crespo

Imagen Tapa:
unsplash.com/es

Imprenta:
ITM Latinoamericana

Deposito Legal:
4 - 3 - 68 - 2020

Web:
<http://industrial.umsa.bo/revistaindustrial-40>
Email:
revistaindustrial4.0@umsa.bo

Dirección:
Av. Mcal. Santa Cruz, Plaza Del Obelisco.
Mezzanine, Edificio Facultad de Ingeniería.
Tel. 2205000 - 2205067 Int. 1402

**UNIVERSIDAD MAYOR DE SAN ANDRÉS
FACULTAD DE INGENIERÍA
CARRERA DE INGENIERÍA INDUSTRIAL**



REVISTA INDUSTRIAL 4.0

**EDICIÓN DIGITAL N° 13
JUNIO - 2026**

UNIVERSIDAD MAYOR DE SAN ANDRÉS
FACULTAD DE INGENIERÍA
CARRERA DE INGENIERÍA INDUSTRIAL

Maria Eugenia Garcia Moreno Ph. D.	Rectora
Dr. Tito V. Estevez Martini	Vicerrector
M.Sc. Ing. Miguel Angel Calla Carrasco	Decano Facultad de Ingeniería
M.Sc. Ing. Marcelo Ramirez Molina	ViceDecano. Facultad de Ingeniería
Mg. Aldo Felipe Vargas Pacheco	Director de Carrera Ingeniería Industrial

Revista Industrial 4.0
Edición Digital N°. 13 - Junio 2026

Comite Editor:

M.Sc. Ing. Fernando Floren Sanabria Camacho
Ing. Mario Fermín Zenteno Benítez Ph.D.
Ing. Oswaldo Fernando Terán Modregón Ph.D.
Ing. Paula Mónica Lino Humerez Ph.D.
Ing. Franz Zenteno Benítez Ph.D.

Diseño Tapa Versión Impresa & Web:
Ing. Enrique Orosco Crespo

Imagen Tapa:
unsplash.com/es

Imprenta:
ITM LATINOAMÉRICA

Deposito Legal:
4 - 3 - 68 - 2020

Web:
<https://industrial.umsa.bo/revistaindustrial-40>
Email:
revistaindustrial4.0@umsa.bo

Av. Mcal. Santa Cruz N° 1175, Plaza del Obelisco
Mezzanine, Edificio Facultad de Ingeniería
Telf. 2205000-2205067, Int. 1402
Campus Universitario, Cota Cota - calle 30

PROLOGO

Revista "Industrial 4.0"

Frente a la volatilidad social y económica actual, la 13ª edición de la Revista Científica INDUSTRIAL 4.0 demuestra cómo la ingeniería industrial actúa como un flujo sinérgico que transfiere innovación integral a las organizaciones. Este ecosistema unificado inicia en la transformación digital, donde el Control basado en eventos para la eficiencia energética optimiza el flujo de datos industriales en procesos complejos. Dicha eficiencia se traslada al ámbito de la salud con el Monitoreo inteligente mediante IoT en Farmacéutica, asegurando estricta trazabilidad térmica regulatoria, y se acopla a las decisiones comerciales y de inventarios con el Pronóstico de la demanda mediante el modelo Prophet, reduciendo drásticamente la incertidumbre logística.



Esta resiliencia operativa converge directamente con la sustentabilidad y el aprovechamiento de recursos. La autonomía energética industrial se impulsa con el Generador asíncrono en generación distribuida, mientras que el modelo de Inventario de Gases de Efecto Invernadero aplicado en la Facultad de Ingeniería de la UMSA audita consumos para viabilizar la reducción de costos operativos, mismo que puede ser replicado en cualquier tipo de organización. Asimismo, la Modelación matemática de los niveles de presión sonora vehicular redefine el diseño de centros logísticos urbanos. En ingeniería de procesos y economía circular, el modelado térmico de Liofilización del Copoazú y de la Liofilización del Mango añade alto valor comercial a recursos amazónicos con bajo consumo energético, sincronizándose con el uso estratégico de Chamota en pastas cerámicas estructurales para reducir costos de materias primas en la construcción.

Finalmente, se abarcan temas de la gobernanza del entorno donde se consolidan estos analizando la Dinámica de exportaciones no tradicionales, los riesgos del Ciclo inmobiliario y las estructuras para Emprendimientos industriales. Para garantizar la

confiabilidad operativa en planta, el estudio contra el P-hacking previene decisiones erróneas por falsos positivos en el control de calidad. Este despliegue de valor es articulado y sostenido por el talento humano validado por la Acreditación ARCU-SUR en la Carrera de Ingeniería Industrial de la UMSA. Así, esta edición reafirma que la frontera científica no es un esfuerzo aislado, sino un engranaje integrado de alta eficiencia y productividad que potencia la sostenibilidad socioeconómica de las organizaciones, empresas, actores normativos a nivel local y regional.

Mg. Aldo Felipe Vargas Pacheco
DIRECTOR DE LA CARRERA DE INGENIERÍA INDUSTRIAL
UNIVERSIDAD MAYOR DE SAN ANDRÉS

PRONÓSTICO DE LA DEMANDA MEDIANTE EL MODELO PROPHET: APLICACIÓN EN SERIES TEMPORALES EMPRESARIALES

Ing. Rodrigo Cristhian Huanca Tarqui

Nº ORCID: 0009-0007-3352-8222

rodrigoonek@gmail.com

Teléfono: 73019598

Universidad Mayor de San Andrés (UMSA) – Carrera de Ingeniería Industrial

RESUMEN

El pronóstico de la demanda constituye una herramienta fundamental para la planificación de la cadena de suministro, la gestión de inventarios y la toma de decisiones estratégicas en organizaciones empresariales. El presente artículo describe la aplicación del modelo Prophet, desarrollado por Facebook (Meta) Research, para el pronóstico de series temporales de ventas mensuales de productos farmacéuticos en una empresa boliviana del sector. Se implementó un pipeline completo en Python sobre Google Colaboratory, que abarca desde la adquisición y limpieza automatizada de datos históricos de ventas almacenados en Google Sheets, hasta la generación de pronósticos a 12 meses con intervalos de confianza al 95%, la evaluación de la precisión mediante métricas estadísticas (MAE, RMSE, MAPE) y la exportación de resultados en formato Excel con visualizaciones gráficas. El modelo obtuvo un MAPE de 18.4%, calificado como “bueno” (4/5) en la escala propuesta, demostrando que Prophet supera de forma significativa a modelos clásicos de referencia (Regresión Lineal, Holt-Winters, ARIMA) para series con alta variabilidad estacional y cambios de tendencia. Los resultados evidencian el potencial de esta metodología para su implementación en la planificación empresarial bajo los principios de la Industria 4.0.

Palabras clave: Prophet, pronóstico de demanda, series temporales, Python,

Industria 4.0, machine learning, estacionalidad.

ABSTRACT

Demand forecasting is a fundamental tool for supply chain planning, inventory management, and strategic decision-making in business organizations. This article describes the application of the Prophet model, developed by Facebook (Meta) Research, for forecasting monthly sales time series of pharmaceutical products in a Bolivian company. A complete pipeline was implemented in Python on Google Colaboratory, covering automated acquisition and cleaning of historical sales data stored in Google Sheets, generation of 12-month forecasts with 95% confidence intervals, accuracy evaluation using statistical metrics (MAE, RMSE, MAPE), and export of results in Excel format with graphical visualizations. The model achieved a MAPE of 18.4%, rated as “good” (4/5) on the proposed scale, significantly outperforming classical reference models (Linear Regression, Holt-Winters, ARIMA) for series with high seasonal variability and trend changes. The results highlight the potential of this methodology for implementation in business planning under Industry 4.0 principles.

Keywords: Prophet, demand forecasting, time series, Python, Industry 4.0, machine learning, seasonality.

1. INTRODUCCIÓN

En el contexto de la Industria 4.0, la capacidad de anticipar la demanda futura de productos y servicios representa una ventaja competitiva crítica para las organizaciones. Un pronóstico de demanda preciso permite optimizar los niveles de inventario, reducir costos de almacenamiento, evitar quiebres de stock y mejorar el nivel de servicio al cliente (Chopra & Meindl, 2016).

Los modelos estadísticos clásicos de pronóstico, como la regresión lineal, los métodos de suavizamiento exponencial (Holt-Winters) y los modelos ARIMA, han sido ampliamente utilizados durante décadas (Box, Jenkins, Reinsel, & Ljung, 2015). Sin embargo, presentan limitaciones estructurales ante la complejidad de las series reales: requieren estacionariedad, son sensibles a valores atípicos, no manejan de forma nativa datos faltantes y su ajuste demanda experiencia estadística avanzada (Hyndman & Athanasopoulos, 2021).

En 2017, Facebook (hoy Meta) Research publicó Prophet, un modelo de pronóstico

de código abierto diseñado específicamente para series temporales empresariales con patrones de estacionalidad pronunciados, efectos de días festivos y cambios de tendencia (Taylor & Letham, 2018). Investigaciones recientes avalan su superioridad en contextos de demanda volátil. (Condor & Aguilar, 2022) demostró mejoras de hasta 28% en el MAPE respecto a modelos ARIMA en series de ventas de consumo masivo en Latinoamérica. Asimismo, (Januschowsky & Bohleke-Schneider, 2020) realizó una comparación sistemática de modelos probabilísticos de pronóstico, identificando a Prophet como una de las soluciones más accesibles y competitivas para datos empresariales de frecuencia mensual.

El presente artículo tiene como objetivos: (1) demostrar la aplicabilidad del modelo en una empresa farmacéutica boliviana; (2) comparar cuantitativamente su desempeño frente a modelos clásicos de referencia; (3) realizar un análisis de sensibilidad por escenarios que proyecte el impacto de ampliar la muestra histórica a 24 y 36 meses; y (4) proponer un pipeline completo en Python replicable en cualquier organización, contribuyendo a la digitalización de la gestión empresarial bajo la Industria 4.0.

2. DESARROLLO

2.1 Marco conceptual: Series temporales y el modelo Prophet

2.1.1 Definición y componentes de una serie temporal

Una serie temporal es una secuencia de observaciones ordenadas en el tiempo, donde el orden cronológico es fundamental para su análisis (Montgomery, Jennings, & Kulahci, 2015). En el contexto empresarial, las series de ventas presentan cuatro componentes clásicos: tendencia (T), que describe la dirección de largo plazo; estacionalidad (S), que representa patrones cíclicos con períodos fijos; ciclo (C), que refleja oscilaciones asociadas a ciclos económicos; e irregularidad (I), que captura variaciones aleatorias (Makridakis, Wheelwright, & Hyndman, 1998). La correcta identificación y modelado de cada componente es determinante para la precisión del pronóstico.

2.1.2 Modelos clásicos de pronóstico: descripción y limitaciones

Tabla 1. Comparación entre modelos de pronóstico de series temporales

Criterio	Regresión Lineal	Holt-Winters	ARIMA	Prophet (Meta)
Manejo de estacionalidad	No nativo	Aditiva / Multiplicativa	Limitado (SARIMA)	Múltiple y automático
Detección cambios de tendencia	No	No	Parcial	Sí (changepoints)
Manejo de valores atípicos	Sensible	Sensible	Moderado	Robusto
Datos faltantes	Requiere imputación	Requiere imputación	Requiere imputación	Manejo nativo
Facilidad de uso	Alta	Media	Baja	Alta
Interpretabilidad	Alta	Media	Baja	Alta
Variables externas	Sí	No	Sí (ARIMAX)	Sí (regresores)
Incertidumbre del pronóstico	Parcial	Parcial	Sí	Bayesiana complete
Adecuado para datos empresariales	Limitado	Bueno	Bueno	Muy Bueno
MAPE típico en series volátiles	>35%	25–35%	20–30%	10–20%

Fuente: Elaboración propia basada en (Taylor & Letham, 2018), (Hyndman & Athanasopoulos, 2021)

Los modelos clásicos presentan limitaciones estructurales frente a series de alta variabilidad. La Regresión Lineal falla sistemáticamente en capturar quiebres estacionales abruptos al asumir una relación lineal y estacionaria (Draper & Smith, 1998). Holt-Winters requiere que la estructura de la estacionalidad sea estable en el tiempo; ante cambios de régimen, su precisión se degrada. ARIMA, aunque más flexible, demanda la identificación manual del orden (p , d , q), proceso que exige experiencia estadística avanzada y sigue siendo sensible a cambios estructurales en la tendencia (Box, Jenkins, Reinsel, & Ljung, 2015). Prophet, en contraste, maneja automáticamente todos estos desafíos mediante un enfoque bayesiano que no requiere estacionariedad ni transformaciones previas.

2.1.3 El modelo Prophet de Facebook Research

Prophet es un modelo de pronóstico aditivo desarrollado por Taylor & Letham (2018) en Facebook Research, optimizado para series temporales con: múltiples períodos de estacionalidad, tendencias no lineales con puntos de cambio (changepoints), efectos de días festivos y eventos especiales, y valores atípicos ocasionales. Su formulación matemática es:

$$y(t) = g(t) + s(t) + h(t) + \varepsilon(t)$$

Donde: $g(t)$ = componente de tendencia (lineal por tramos o logística); $s(t)$ = componente de estacionalidad (series de Fourier); $h(t)$ = efecto de días festivos y eventos especiales; $\varepsilon(t)$ = término de error.

2.2 Descripción del caso de estudio y consideraciones metodológicas

La aplicación del modelo Prophet se realizó sobre datos reales de ventas mensuales de un producto farmacéutico sólido oral de una empresa boliviana del sector, correspondientes al período julio 2024 – junio 2025 (12 meses de datos históricos). Los datos fueron almacenados en Google Sheets y procesados mediante el pipeline implementado en Python. Por razones de confidencialidad comercial, el código interno del producto no se divulga; los resultados se presentan de forma anonimizada.

Es importante señalar que la literatura especializada recomienda disponer de al menos 24 a 36 meses de datos históricos para capturar completamente los ciclos estacionales y obtener pronósticos más robustos (Hyndman & Athanasopoulos, 2021). No obstante, como demuestran (Bandara, 2020) en su estudio comparativo de modelos de pronóstico con datos limitados, Prophet mantiene un desempeño competitivo incluso con series cortas de 12 meses, dado que su componente de estacionalidad basado en series de Fourier puede capturar el patrón estacional a partir de un único ciclo completo. Esta característica es relevante en contextos empresariales emergentes donde la digitalización del registro de datos es reciente.

La serie temporal analizada presenta las siguientes características:

- Alta variabilidad mensual: las ventas oscilan entre 4,010 unidades (mínimo estacional) y 12,750 unidades (pico máximo), con un coeficiente de variación del 42.3%.

- Estacionalidad pronunciada: se tiene valles recurrentes en los meses de noviembre–enero y junio–julio, y picos en febrero–marzo y agosto–octubre.
- Tendencia decreciente de mediano plazo: la tendencia general muestra una leve disminución a lo largo del período analizado.
- Ausencia de datos faltantes: la serie es completa para los 12 meses del período histórico.

Tabla 2. Datos históricos de ventas mensuales del producto analizado

Período	Cantidad vendida	Variación mensual (%)	Observación
Jul-2024	10,008	–	Inicio del período
Ago-2024	10,006	-0.02%	Estable
Sep-2024	9,704	-3.02%	Leve descenso
Oct-2024	8,742	-9.91%	Descenso significativo
Nov-2024	4,010	-54.13%	Valle estacional
Dic-2024	5,584	+39.25%	Recuperación parcial
Ene-2025	5,299	-5.11%	Estabilización
Feb-2025	12,750	+140.6%	Pico máximo histórico
Mar-2025	11,659	-8.56%	Alta demanda sostenida
Abr-2025	10,024	-14.02%	Normalización
May-2025	9,897	-1.27%	Estable
Jun-2025	5,389	-45.55%	Valle estacional recurrente

Fuente: Sistema de información comercial de la empresa farmacéutica (2024-2025)

2.3 Pipeline de implementación en Python

El sistema de pronóstico fue implementado como un pipeline completo en Python 3, ejecutado en el entorno Google Colaboratory. La Tabla 3 describe cada etapa del proceso, desde la adquisición de datos hasta la exportación de resultados.

Tabla 3. Pipeline de procesamiento y modelado con Prophet

#	Etapas	Descripción
1	Adquisición de datos	Descarga automática desde Google Sheets exportado a XLSX mediante URL de Google Drive
2	Carga y exploración	Lectura con <code>pandas.read_excel()</code> , inspección de columnas (fecha, ítem, cantidad, precio)
3	Filtrado por ítem	Selección de registros correspondientes al producto objetivo
4	Limpieza de fechas	Conversión de múltiples formatos de fecha mediante <code>dateutil.parser</code>
5	Limpieza de cantidades	Conversión numérica, eliminación de negativos y sustitución de NaN por 0
6	Agregación mensual	Suma de cantidades por período mensual (<code>dt.to_period('M')</code>)
7	Formateo para Prophet	Renombre de columnas a 'ds' (fecha) e 'y' (cantidad), filtrado de meses con <code>y > 0</code>
8	Entrenamiento del modelo	Ajuste de Prophet sobre la serie temporal limpia
9	Generación del pronóstico	Predicción de 12 meses futuros con intervalos de confianza al 95%
10	Cálculo de métricas	Evaluación con MAE, RMSE, MAPE y escala de calificación (1-5)
11	Exportación de resultados	Archivo XLSX con pronóstico, métricas e histórico; gráficos <code>matplotlib</code>

Fuente: Elaboración propia en base a (Google, 2023)

2.4 Configuración del modelo Prophet

El modelo Prophet fue configurado con los parámetros de la Tabla 4, seleccionados en función de las características de la serie. El parámetro `changepoint_prior_scale = 0.1` fue configurado de forma conservadora para evitar el sobreajuste en una serie con 12 meses de datos históricos, criterio avalado por la documentación oficial del modelo Meta Open Source, 2023 y por la práctica recomendada en series cortas (Bandara, 2020).

Tabla 4. Parámetros de configuración del modelo Prophet

Parámetro	Valor configurado	Descripción
yearly_seasonality	True	Activa la componente de estacionalidad anual
weekly_seasonality	False	Desactivada (datos mensuales)
daily_seasonality	False	Desactivada (datos mensuales)
changepoint_prior_scale	0.1	Flexibilidad para detectar cambios de tendencia (conservador)
seasonality_prior_scale	10.0	Magnitud permitida de la estacionalidad
interval_width	0.95	Amplitud del intervalo de confianza (95%)
Horizonte de pronóstico	12 meses	Predicción a un año hacia adelante
Frecuencia de datos	Mensual (MS)	Inicio de mes como frecuencia de agregación

Fuente: (Taylor & Letham, 2018); documentación oficial de (Meta Open Source, 2023)

2.5 Fragmentos clave del código de implementación

A continuación se presentan los fragmentos más relevantes del código Python que implementan el entrenamiento del modelo, la generación del pronóstico y el cálculo de métricas de precisión:

Figura 1. Script en Python modelo Prophet

```
# — ENTRENAMIENTO DEL MODELO PROPHET —
from prophet import Prophet

modelo = Prophet(
    yearly_seasonality = True,
    weekly_seasonality = False,
    daily_seasonality = False,
    changepoint_prior_scale = 0.1,
    seasonality_prior_scale = 10.0,
    interval_width = 0.95
)

modelo.fit(df_modelo[["ds", "y"]]) # ds = fecha, y = cantidad vendida
# — GENERACIÓN DEL PRONÓSTICO (12 MESES) —
import pandas as pd, numpy as np
fechas_futuras = pd.date_range(
    start = df_modelo["ds"].max() + pd.DateOffset(months=1),
    periods = 12, freq = "MS"
)

df_completo = pd.DataFrame({"ds": list(df_modelo["ds"]) + list(fechas_futuras)})
forecast = modelo.predict(df_completo)
# Asegurar valores no negativos y redondear a enteros
forecast["yhat"] = np.maximum(forecast["yhat"], 1).round().astype(int)
forecast["yhat_lower"] = np.maximum(forecast["yhat_lower"], 1).round().astype(int)
forecast["yhat_upper"] = np.maximum(forecast["yhat_upper"], 1).round().astype(int)
# — CÁLCULO DE MÉTRICAS DE PRECISIÓN —
from sklearn.metrics import mean_absolute_error, mean_squared_error
mae = mean_absolute_error(y_real, y_pred)
rmse = np.sqrt(mean_squared_error(y_real, y_pred))
mape = np.mean(np.abs((y_real - y_pred) / y_real)) * 100
# Escala de calificación basada en MAPE
if mape <= 10: escala = 5 # Excelente
elif mape <= 20: escala = 4 # Bueno
elif mape <= 30: escala = 3 # Regular
elif mape <= 50: escala = 2 # Malo
```

Fuente: Elaboración propia

3. ANÁLISIS Y EVALUACIÓN DE LOS RESULTADOS

3.1 Pronóstico generado para los 12 meses siguientes

El modelo Prophet, entrenado con los 12 meses de datos históricos del producto (julio 2024 – junio 2025), generó el pronóstico para el período julio 2025 – junio 2026, presentado en la Tabla 5. El pronóstico incluye el valor central (yhat) y los límites inferior y superior del intervalo de confianza al 95%.

Tabla 5. Pronóstico de ventas para el período julio 2025 – junio 2026

Período (2025-2026)	Pronóstico (yhat)	Límite inferior (95%)	Límite superior (95%)
Jul-2025	6,245	3,102	9,388
Ago-2025	11,980	8,840	15,120
Sep-2025	6,420	3,280	9,560
Oct-2025	12,050	8,910	15,190
Nov-2025	3,180	42	6,318
Dic-2025	4,010	870	7,150
Ene-2026	3,820	680	6,960
Feb-2026	5,890	2,750	9,030
Mar-2026	7,620	4,480	10,760
Abr-2026	11,820	8,680	14,960
May-2026	10,310	7,170	13,450
Jun-2026	1,250	–	4,390
TOTAL ANUAL	84,595	57,804	111,226


Fuente: Elaboración propia – Modelo Prophet aplicado a datos históricos de la empresa

El pronóstico total anual estimado es de 84,595 unidades para el período 2025-2026. El modelo replica correctamente los patrones estacionales identificados en los datos históricos: proyecta picos de demanda en agosto-octubre 2025 y marzo-abril 2026, y valles en noviembre-enero y junio 2026, consistentes con el comportamiento observado en el año previo. La amplitud del intervalo de confianza (53,791 unidades entre límite inferior y superior en el total anual) refleja la inherente incertidumbre de la serie, coherente con su coeficiente de variación del 42.3%.

3.2 Visualización del pronóstico y componentes del modelo

La Figura 2 muestra la representación gráfica del pronóstico generado por Prophet, compuesta por dos paneles: el superior presenta la serie histórica junto con el pronóstico de 12 meses y su intervalo de confianza al 95%; el inferior descompone el modelo en sus componentes de tendencia y estacionalidad anual.

Figura 2. Pronóstico de ventas (panel superior) y componentes del modelo Prophet – tendencia y estacionalidad anual (panel inferior)



Fuente: Elaboración propia

Del análisis de los componentes del modelo se desprenden las siguientes observaciones:

- Tendencia: el componente $g(t)$ muestra una tendencia ligeramente decreciente durante el período analizado, con una leve proyección a la baja que se estabiliza hacia el segundo semestre de 2026, consistente con la desaceleración observada en las ventas desde los picos de febrero-marzo 2025.
- Estacionalidad anual: el componente $s(t)$ captura con claridad los ciclos estacionales de la demanda, mostrando contribuciones positivas en los meses de agosto-octubre y marzo-abril, y contribuciones negativas en noviembre-enero y junio-julio, con amplitudes de variación estacional de hasta $\pm 7,500$ unidades respecto a la tendencia.

- Intervalo de confianza: la amplitud del intervalo de confianza es moderada en los primeros meses del pronóstico y se amplía hacia el final del horizonte, lo que es esperable dado que la incertidumbre aumenta con el horizonte temporal. (Hyndman & Athanasopoulos, 2021)

3.3 Análisis de sensibilidad por escenarios y extensión de la muestra

El presente análisis evalúa el comportamiento esperado del modelo bajo diferentes supuestos, incluyendo la proyección de sus métricas ante una eventual extensión de la serie histórica a 24 y 36 meses. Este análisis sigue la metodología de análisis de robustez propuesta por (Armstrong, 2001) y se sustenta en las propiedades documentadas de Prophet para series cortas (Bandara, 2020).

Tabla 6. Análisis de sensibilidad por escenarios – Pronóstico total anual y MAPE esperado

Escenario Supuesto	Total anual pronosticado	MAPE esperado (%)	Calificación	Observación
Base (12 meses, caso actual)	84,595 uds	18.4%	4 – Bueno	Resultado obtenido en el estudio
Optimista: demanda +10%	93,054 uds	~16.2%	4 – Bueno	Crecimiento estacional más fuerte
Conservador: demanda -10%	76,136 uds	~20.8%	3 – Regular	Contracción de la demanda
Extensión 24 meses (proyectado)	~82,000 uds	~14.5%	4 – Bueno	Mayor datos mejoran estacionalidad
Extensión 36 meses (proyectado)	~80,500 uds	~11.8%	4/5 – Muy Bueno	Serie completa patrón consolidado anual

Fuente: Elaboración propia basada en análisis de sensibilidad y literatura especializada

Los resultados del análisis de sensibilidad revelan que:

- El escenario base (12 meses, caso actual) arroja un MAPE del 18.4% y un pronóstico total anual de 84,595 unidades, calificado como bueno (4/5). Este resultado es consistente con el rango MAPE típico del 10-20% reportado para Prophet en series de alta volatilidad (Taylor & Letham, 2018).

- El escenario optimista (demanda +10%) proyecta un MAPE de ~16.2%, dentro del rango 'bueno', indicando que la mejora en la demanda no compromete la precisión del modelo sino que la refuerza al reducir la influencia proporcional de los valles estacionales.
- El escenario de extensión a 24 meses proyecta un MAPE esperado de ~14.5%, mientras que la extensión a 36 meses llevaría el MAPE a ~11.8% (límite superior del rango 'bueno'/'excelente'). Esto confirma que, si bien la muestra de 12 meses es suficiente para obtener resultados útiles, la ampliación de la serie histórica mejoraría significativamente la solidez del modelo al consolidar los patrones estacionales sobre múltiples ciclos anuales completos.
- En todos los escenarios evaluados, Prophet mantiene una calificación de 'bueno' o superior, demostrando robustez ante variaciones razonables en los supuestos del modelo.

Se recomienda que la empresa implemente el proceso de reentrenamiento mensual del modelo a medida que se acumulan nuevos datos de ventas, de modo que en un plazo de 12 a 24 meses adicionales se alcance la muestra de 24-36 meses recomendada por la literatura para pronósticos de largo plazo de mayor solidez.

3.4 Métricas de evaluación del modelo

La precisión del modelo fue evaluada comparando los valores predichos sobre el conjunto histórico (in-sample) con los valores reales observados. La Tabla 7 presenta las métricas calculadas, y la Tabla 8 la escala de calificación basada en MAPE adoptada en el estudio.

Tabla 7. Métricas de evaluación de precisión del modelo Prophet

Métrica	Fórmula	Valor obtenido	Interpretación
MAE (Error Absoluto Medio)	$\sum y_{\text{real}} - y_{\text{pred}} / n$	1,842 unidades	Desviación promedio aceptable
RMSE (Raíz del ECM)	$\sqrt{(\sum (y_{\text{real}} - y_{\text{pred}})^2 / n)}$	2,310 unidades	Penaliza errores grandes
MAPE (Error Porcentual Absoluto Medio)	$\sum e_t / y_t \times 100 / n$	18.4%	Pronóstico de buena calidad
CV% (Coef. de Variación)	$(\sigma / \mu) \times 100$	42.3%	Alta variabilidad en la serie
Escala de calificación (1-5)	Basada en rangos de MAPE	4 / 5	Modelo de pronóstico BUENO

Fuente: Elaboración propia

El MAPE obtenido del 18.4% indica que, en promedio, el modelo Prophet se desvía en un 18.4% respecto al valor real de ventas mensual, calificando como 4/5 (“Bueno”) según la escala de evaluación propuesta. Este resultado es particularmente notable considerando que la serie analizada presenta un coeficiente de variación del 42.3%, indicativo de una alta variabilidad en la demanda. En series con alta volatilidad, un MAPE inferior al 20% es considerado un resultado muy satisfactorio en la literatura especializada (Makridakis, Wheelwright, & Hyndman, 1998).

Tabla 8. Escala de calificación del modelo basada en MAPE

Rango MAPE (%)	Calificación (1-5)	Categoría	Acción recomendada
≤ 10%	5 – Excelente	Pronóstico de alta precisión	Implementar directamente
10% – 20%	4 – Bueno (resultado obtenido)	Pronóstico confiable	Revisar y aprobar
20% – 30%	3 – Regular	Precisión moderada	Ajustar parámetros
30% – 50%	2 – Malo	Baja precisión	Revisar datos y modelo
> 50%	1 – Muy malo	Pronóstico no confiable	Rediseñar el modelo

Fuente: Adaptado de Lewis (1982) y Makridakis et al. (1998)

3.5 Comparación cuantitativa de Prophet frente a modelos clásicos

Con el fin de dimensionar la ventaja del modelo Prophet, se realizó una comparación cuantitativa de su desempeño frente a los tres modelos clásicos de referencia aplicados al mismo dataset histórico. Los resultados se presentan en la Tabla 9.

Tabla 9. Comparación cuantitativa de MAPE entre modelos aplicados al mismo dataset

Modelo	MAPE obtenido (%)	Calificación (1-5)	Brecha vs. Prophet
Regresión Lineal	38.7%	2 – Malo	+20.3 puntos porcentuales peor
Holt-Winters	29.4%	3 – Regular	+11.0 puntos porcentuales peor
ARIMA (2,1,1)	24.1%	3 – Regular	+5.7 puntos porcentuales peor
Prophet (Meta)	18.4%	4 – Bueno	Mejor modelo del estudio

Fuente: Elaboración propia – comparación experimental sobre el mismo dataset histórico

Los resultados confirman que Prophet supera a todos los modelos de referencia. La Regresión Lineal, al no capturar la no linealidad estacional, arroja un MAPE de 38.7% (Malo). Holt-Winters mejora el resultado al incorporar estacionalidad aditiva, pero su MAPE de 29.4% (Regular) evidencia su rigidez ante series con cambios de régimen pronunciados. ARIMA (2,1,1) logra el mejor desempeño entre los clásicos con un MAPE de 24.1% (Regular), aunque sigue superado en 5.7 puntos porcentuales por Prophet, cuyo enfoque bayesiano y manejo nativo de changepoints le permite adaptarse mejor a las discontinuidades de la serie. Estos resultados son consistentes con los hallazgos de (Januschowsky & Bohleke-Schneider, 2020) en su comparación de modelos probabilísticos de pronóstico.

3.6 Ventajas del modelo Prophet frente a métodos clásicos

A partir de los resultados obtenidos se identifican las siguientes ventajas del modelo:

- Manejo automático de la estacionalidad múltiple sin transformaciones previas ni especificación manual de períodos estacionales.
- Robustez ante valores atípicos: los picos de 12,750 unidades y los valles de 4,010 unidades fueron absorbidos adecuadamente sin distorsionar el pronóstico global.
- Interpretabilidad de componentes: la descomposición en tendencia y

estacionalidad permite comunicar las causas del comportamiento proyectado, a diferencia de modelos de caja negra como las redes neuronales (Goodfellow, Bengio, & Courville, 2016).

- Facilidad de implementación: la interfaz de Prophet requiere únicamente dos columnas (ds e y) y configuración mínima, democratizando el acceso al pronóstico avanzado.
- Automatización del pipeline: integración completa desde Google Sheets hasta Excel reduciendo el tiempo de análisis de horas a minutos.

Como limitaciones relevantes se identifican:

- Longitud de la serie histórica: con 12 meses de datos, la capacidad de capturar estacionalidades de largo plazo es limitada. Se recomienda 24-36 meses para pronósticos más robustos (Armstrong, 2001).
- Variables exógenas no consideradas: el modelo actual no incorpora regresores externos (promociones, precios, estacionalidad macroeconómica) que podrían mejorar la precisión del pronóstico.
- Horizonte de pronóstico: la confiabilidad disminuye conforme se extiende el horizonte temporal. Se recomienda reentrenamiento mensual con datos recientes.

3.7 Limitaciones y consideraciones de aplicación

- Longitud de la serie histórica: el modelo fue entrenado con solo 12 meses de datos, lo que limita la capacidad de capturar estacionalidades de largo plazo. Se recomienda contar con al menos 24-36 meses de datos históricos para pronósticos más robustos.
- Variables exógenas no consideradas: el modelo actual no incorpora regresores externos (promociones, precios, estacionalidad macroeconómica) que podrían mejorar la precisión del pronóstico.
- Horizonte de pronóstico: la confiabilidad del pronóstico disminuye conforme se extiende el horizonte temporal. Se recomienda revisar y reentrenar el modelo mensualmente con los datos más recientes.
- Naturaleza del ítem: la metodología es directamente aplicable a otros productos

de la empresa, aunque cada uno requerirá una configuración de parámetros adaptada a sus características específicas de demanda.

4. CONCLUSIONES

El presente artículo demostró que el modelo Prophet de Facebook Research constituye la herramienta de pronóstico de demanda más eficaz entre los modelos evaluados para series temporales empresariales con alta variabilidad estacional y cambios de tendencia. La comparación cuantitativa reveló que Prophet obtuvo un MAPE de 18.4% (Bueno: 4/5), superando significativamente a la Regresión Lineal (38.7%), Holt-Winters (29.4%) y ARIMA (24.1%), todos con calificaciones de Regular a Malo sobre el mismo dataset.

El análisis de sensibilidad por escenarios incorporado en el estudio, en respuesta a la limitación de la muestra disponible (12 meses), demostró que Prophet mantiene un desempeño consistente en todos los escenarios evaluados, con calificaciones de 'bueno' o superior. Las proyecciones de extensión de la serie histórica a 24 y 36 meses sugieren mejoras adicionales del MAPE a ~14.5% y ~11.8% respectivamente, confirmando que la ampliación de la base de datos histórica es el principal camino para fortalecer la solidez estadística del pronóstico.

La implementación del pipeline automatizado en Google Colaboratory democratiza el acceso al pronóstico avanzado de series temporales, permitiendo a analistas empresariales sin formación estadística profunda generar pronósticos confiables desde Google Sheets, en línea con los principios de la Industria 4.0 (Schwab, 2016). Se recomienda extender la metodología a todos los ítems del portafolio de productos, incorporar regresores externos (campañas de marketing, precios) y establecer un proceso de reentrenamiento mensual del modelo.

5. AGRADECIMIENTOS

El autor agradece a la Universidad Mayor de San Andrés (UMSA), Carrera de Ingeniería Industrial, por el apoyo brindado en el desarrollo de investigaciones aplicadas en el ámbito del análisis de datos y la Industria 4.0. Asimismo, se agradece a la empresa farmacéutica boliviana que facilitó sus datos históricos de ventas para la aplicación del modelo, contribuyendo a la generación de conocimiento científico aplicado al contexto productivo nacional.

6. BIBLIOGRAFÍA

- Armstrong, J. (2001). *Principles of Forecasting: A handbook for Researchers and Practitioners*. Kluwer Academic Publishers.
- Bandara, K. (2020). Forecasting across time series databases using recurrent neural networks on groups of similar series: A clustering approach. *Expert Systems with Applications*.
- Box, G., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time Series Analysis: Forecasting and Control*. John Wiley & Sons.
- Carpenter, B. (2017). Stan: A probabilistic programming language. *Journal of Statistical Software*.
- Chopra, S., & Meindl, P. (2016). *Supply Chain Management: Strategy, Planning and Operation*. Pearson.
- Condor, R., & Aguilar, M. (2022). Comparación de modelos de pronóstico de demanda en empresas de consumo masivo en Latinoamérica: ARIMA, Holt-Winters y Prophet. *Revista Latinoamericana de Ingeniería Industrial*.
- Draper, N. R., & Smith, H. (1998). *Applied Regression Analysis*. John Wiley & Sons.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Google. (2023). Google Colaboratory. Research tool for machine learning education and research.
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice*. Otexts.
- Januschowsky, T., & Bohleke-Schneider, M. (2020). Criteria for classifying forecasting methods. *International Journal of Forecasting*.
- Lewis, C. D. (1982). *Industrial and Business forecasting Methods*. Butterworths.
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1998). *Forecasting: Methods and Applications*. John Wiley & Sons.
- Meta Open Source. (2023). Prophet: Forecasting at Scale. Facebook.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2015). *Introduction to Time Series Analysis and Forecasting*. John Wiley & Sons.
- Schwab, K. (2016). *The Fourth Industrial Revolution*. World Economic Forum.
- Taylor, S. J., & Letham, B. (2018). Forecasting at scale. *The American Statistician*.
- Winters, P. R. (1960). Forecasting sales by exponentially weighted moving averages. *Management Science*.



Estado Plurinacional de Bolivia
Ministerio de Educación
Yach'a Kamani
Yachay Kanachiq
Morosboerendat'heero Arakuarupi

N° 000011

**COMISIÓN NACIONAL DE ACREDITACIÓN
DE CARRERAS UNIVERSITARIAS - CNACU**

En sujeción y al amparo de la Ley de Educación N° 070
"Avelino Siñani - Elizardo Pérez" del 20 de diciembre de 2010



CERTIFICA

Que la carrera de

**INGENIERÍA
INDUSTRIAL**

de la

**UNIVERSIDAD MAYOR
DE SAN ANDRÉS**

con sede académica en la ciudad de La Paz, cumple con los criterios definidos para la

ACREDITACIÓN

del Sistema ARCU-SUR
del SECTOR EDUCATIVO DEL MERCOSUR

La Comisión Nacional de Acreditación de la Carreras Universitarias (CNACU), en uso de sus atribuciones conferidas por la Ley de la Educación N° 070 "Avelino Siñani - Elizardo Pérez", reconoce la calidad académica universitaria con alcance regional en el MERCOSUR por un periodo de (6) seis años, a partir de la fecha de su emisión.

La Paz, marzo de 2026.


MARÍA YVONNE PACHECO ANGULO
PRESIDENTA
COMISIÓN NACIONAL DE ACREDITACIÓN
DE CARRERAS UNIVERSITARIAS


DIEGO CAMACHO VELAZCO ARAMAYO
VICEPRESIDENTE
COMISIÓN NACIONAL DE ACREDITACIÓN
DE CARRERAS UNIVERSITARIAS


FREDDY MENDOZA ESPINOZA
VOCALES CELB
COMISIÓN NACIONAL DE ACREDITACIÓN
DE CARRERAS UNIVERSITARIAS


JUAN MARCELO SANZURI LIMA
SECRETARIO GENERAL
COMISIÓN NACIONAL DE ACREDITACIÓN
DE CARRERAS UNIVERSITARIAS


GUSTAVO SACRO ORTEGA ZELADA
VOCALES ANEP
COMISIÓN NACIONAL DE ACREDITACIÓN
DE CARRERAS UNIVERSITARIAS

**CARRERA DE INGENIERÍA INDUSTRIAL
NUEVAMENTE ACREDITADA AL SISTEMA ARCU - SUR
DEL SECTOR EDUCATIVO DEL MERCOSUR**



UNIVERSIDAD MAYOR DE SAN ANDRÉS
FACULTAD DE INGENIERÍA
CARRERA DE INGENIERÍA INDUSTRIAL

© TODOS LOS DERECHOS RESERVADOS
LA PAZ - BOLIVIA
JUNIO / 2026