

**Comparativa de modelos predictivos de repuestos en mantenimiento industrial mediante
ciencia de datos**

Andres Daniel Ortega Castro

Asesor

Felipe Alexander Pipicano Guzman

Universidad Nacional Abierta y a Distancia UNAD
Escuela de Ciencias Básicas, Tecnología e Ingeniería ECBTI
Especialización En Ciencia de Datos y Analítica

2026

Nota de Aceptación

Nombre Director de Trabajo de Grado

Jurado

Jurado

Agradecimientos

Quiero expresar mi agradecimiento a ORGANIZACION MAS S.A.S, especialmente al equipo del área de mantenimiento, por facilitarme el acceso a la información necesaria para el desarrollo de este proyecto. Su disposición para compartir datos, explicar procesos y permitir el análisis de los registros históricos fue fundamental para la realizar una comparativa de modelos predictivos.

Agradezco también la apertura institucional para apoyar iniciativas enfocadas en mejorar la gestión del mantenimiento mediante ciencia de datos. Este trabajo no habría sido posible sin su colaboración y confianza.

Resumen

En la presente investigación se aborda el problema de la predicción de demanda en inventarios de repuestos de mantenimiento industrial, caracterizados por un comportamiento altamente intermitente y variable. El estudio se desarrolló en la empresa Organización MAS S.A.S., utilizando información histórica de consumo extraída del sistema SAP Business One correspondiente al periodo 2021–2025.

Inicialmente se realizó un proceso de depuración, agregación mensual y análisis exploratorio de datos, con el fin de caracterizar estadísticamente las series temporales de 36 materiales críticos. Mediante métricas como el porcentaje de meses sin consumo, el coeficiente de variación y el Average Demand Interval (ADI), se determinó que la mayoría de los repuestos presentan demanda intermitente o errática, condición que limita la aplicabilidad de modelos tradicionales de pronóstico.

Posteriormente se implementó y evaluó comparativamente cuatro enfoques predictivos: ARIMA + Red Neuronal, CNN + LSTM, CNN + GRU + BiLSTM + Atención y Prophet. El desempeño se midió mediante MAE, RMSE y R^2 , permitiendo analizar la estabilidad y capacidad de ajuste de cada modelo frente a distintos patrones de consumo. Los resultados evidencian que Prophet presenta mayor estabilidad global en series altamente irregulares, mientras que las arquitecturas de aprendizaje profundo muestran mejor desempeño en materiales con patrones temporales definidos.

El principal aporte del estudio radica en la identificación de las condiciones estadísticas bajo las cuales es viable aplicar modelos predictivos en inventarios de mantenimiento industrial, proponiendo un enfoque diferenciado según el nivel de intermitencia de cada material. Esta

aproximación permite fortalecer la planificación de repuestos, reducir riesgos de quiebre de stock y mejorar la toma de decisiones basada en datos en entornos industriales.

Palabras claves: Demanda intermitente, Mantenimiento industrial, Series de tiempo, Deep learning, Gestión de inventarios.

Abstract

This research addresses the problem of demand forecasting in industrial maintenance spare parts inventories, which are typically characterized by intermittent and highly variable consumption patterns. The study was conducted at ORGANIZACION MAS S.A.S., using historical consumption data extracted from SAP Business One for the period 2021–2025.

A comprehensive data preparation process was carried out, including data cleaning, monthly aggregation, and exploratory data analysis to statistically characterize the time series of 36 critical spare parts. Using metrics such as the percentage of zero-demand periods, coefficient of variation, and Average Demand Interval (ADI), most materials were classified as intermittent or erratic demand items. This condition significantly affects the applicability and performance of conventional forecasting models.

Four predictive approaches were implemented and comparatively evaluated: ARIMA combined with Neural Networks, CNN + LSTM, CNN + GRU + BiLSTM with Attention mechanism, and Prophet. Model performance was assessed using MAE, RMSE, and R^2 metrics to evaluate accuracy, stability, and explanatory capacity across different demand patterns. The results show that Prophet provides greater overall stability for highly irregular series, while deep learning architectures achieve superior performance for materials exhibiting clearer temporal structures.

The main contribution of this study lies in identifying the statistical conditions under which predictive models are methodologically suitable for spare parts inventory forecasting in maintenance environments. The findings support a differentiated modeling strategy based on demand intermittency, enhancing spare parts planning, reducing stockout risks, and strengthening data-driven decision-making in industrial contexts.

Keywords: Intermittent demand, Industrial maintenance, Time series forecasting, Deep learning, Inventory management.

Tabla de Contenido

Introducción	13
Planteamiento del Problema	15
Justificación	16
Objetivos	18
Objetivo General	18
Objetivos Específicos.....	18
Descripción del Problema	19
Marco de Referencia	21
Gestión del Mantenimiento Industrial.....	21
Gestión de Inventarios de Repuestos	21
Demanda Intermitente en Inventarios Industriales	22
Modelos Predictivos en Series Temporales	23
Modelos Estadísticos.....	23
Modelos de Aprendizaje Profundo.....	23
Métricas de Evaluación en Forecasting	24
Sistema ERP y SAP Business One	24
Metodología	26
Diseño General del Enfoque Metodológico.....	26
Preparación del Entorno y Librerías	27
Caracterización del Conjunto de Datos.....	27
Análisis de Datos	30
Análisis Exploratorio de Datos	31

Limpieza y Preparación de Datos	36
Normalización de Nombres de Columnas.....	36
Conversión de Fechas	36
Conversión de Tipos de Datos	36
Depuración de Registros	37
Modelos Predictivos Implementados	37
Modelo Híbrido CNN + LSTM.....	37
Modelo CNN + GRU + BiLSTM + Atención.....	44
Modelo Prophet (Meta/Facebook).....	51
Modelo ARIMA + Red Neuronal.....	56
Resultados	64
Comparación General de Desempeño.....	64
Comparación del RMSE	65
Comparación del Coeficiente R^2	65
Análisis Comparativo Consolidado	66
Estabilidad de Prophet.....	67
Desempeño de Modelos Neuronales en Series Estructuradas.....	67
Limitaciones en Series Altamente Irregulares	67
Ausencia de un Modelo Universal	68
Visualización Comparativa Multidimensional.....	68
Clasificación de Materiales Según Viabilidad Predictiva.....	72
Conclusiones	92
Recomendaciones	94

Referencias.....96

Lista de Tablas

Tabla 1 <i>Características del Conjunto de Datos</i>	29
Tabla 2 <i>Ranking Comparativo de Modelos Predictivos</i>	66
Tabla 3 <i>Clasificación de Materiales Según Nivel de Intermitencia y Predictibilidad</i>	73

Lista de Figuras

Figura 1 <i>Consumos Históricos de Tela 10xxx</i>	32
Figura 2 <i>Consumos Históricos de Correa M49</i>	33
Figura 3 <i>Distribución de Consumo Mensual de Repuestos</i>	35
Figura 4 <i>Comparación del MAE Promedio por Modelo</i>	68
Figura 5 <i>Comparación del RMSE Promedio por Modelo</i>	69
Figura 6 <i>Comparación del R² Promedio por Modelo</i>	70
Figura 7 <i>Radar Chart Comparativo de Modelos</i>	71

Introducción

En los entornos industriales, la gestión de inventarios de repuestos de mantenimiento representa un desafío estratégico debido a la naturaleza irregular de su demanda. A diferencia de los inventarios comerciales, los repuestos industriales suelen presentar consumos esporádicos, largos periodos sin movimiento y picos abruptos asociados a fallas o intervenciones no programadas. Este comportamiento, conocido en la literatura como demanda intermitente o errática, dificulta la aplicación de modelos tradicionales de pronóstico y limita la precisión en la planificación del abastecimiento.

Una predicción inadecuada puede generar dos consecuencias opuestas, pero igualmente costosas: exceso de inventario, con inmovilización de capital y riesgo de obsolescencia; o quiebres de stock, que pueden ocasionar paradas no programadas y afectar la continuidad operativa. Por ello, comprender la estructura estadística de la demanda y evaluar la pertinencia de distintos enfoques predictivos se convierte en un problema técnico relevante tanto para la gestión industrial como para la ciencia de datos aplicada.

En la empresa ORGANIZACION MAS S.A.S., el consumo histórico de repuestos se encuentra registrado en el sistema SAP Business One; sin embargo, dicha información no ha sido explotada mediante análisis predictivos formales. Esta situación evidencia la necesidad de transformar los datos históricos en modelos capaces de anticipar comportamientos futuros, considerando la alta variabilidad y la presencia significativa de intermitencia en las series de tiempo.

El presente estudio tiene como propósito analizar el comportamiento estadístico de la demanda de 36 repuestos críticos y evaluar comparativamente distintos modelos de predicción, incluyendo enfoques estadísticos automatizados y arquitecturas de aprendizaje profundo. Más

allá de determinar cuál modelo obtiene menor error promedio, la investigación busca identificar bajo qué condiciones estructurales cada enfoque resulta metodológicamente adecuado.

De esta manera, el trabajo no solo aporta una comparación cuantitativa de modelos, sino que propone un marco de decisión basado en el nivel de intermitencia de la demanda, contribuyendo a la mejora de la planificación de inventarios en mantenimiento industrial y al fortalecimiento de la toma de decisiones basada en datos.

Planteamiento del Problema

La predicción de la demanda en inventarios de repuestos para mantenimiento industrial representa un reto metodológico significativo debido a la naturaleza irregular del consumo. A diferencia de otros entornos donde la demanda presenta patrones relativamente estables o estacionales, los repuestos industriales suelen caracterizarse por consumos intermitentes, alta proporción de períodos sin movimiento y variaciones abruptas asociadas a fallas o intervenciones correctivas. Este comportamiento dificulta la aplicación directa de modelos tradicionales de pronóstico y pone en duda la efectividad de enfoques más complejos cuando no se considera previamente la estructura estadística de la serie.

En ORGANIZACION MAS S.A.S. se dispone de información histórica detallada del consumo de repuestos registrada en SAP Business One; sin embargo, no se ha realizado una caracterización cuantitativa que permita identificar el nivel de intermitencia, variabilidad o regularidad de cada material. En ausencia de este análisis, la aplicación de modelos predictivos puede generar resultados inconsistentes, especialmente cuando se emplean técnicas diseñadas para series con comportamiento más estructurado.

La problemática no se limita a la falta de modelos de predicción, sino a la ausencia de criterios técnicos que orienten su selección y aplicación. Implementar un modelo sin evaluar previamente la naturaleza de la demanda puede conducir a estimaciones poco confiables, afectando la planificación de inventarios y aumentando el riesgo tanto de sobreabastecimiento como de desabastecimiento.

Justificación

La gestión de inventarios de repuestos en mantenimiento industrial constituye un problema estratégico que impacta directamente la continuidad operativa y la eficiencia financiera de las organizaciones. A diferencia de los inventarios comerciales, los repuestos presentan patrones de consumo irregulares y altamente variables, lo que dificulta la planificación y genera un alto nivel de incertidumbre en la toma de decisiones. Esta condición exige un enfoque analítico riguroso que permita comprender la estructura estadística de la demanda antes de aplicar técnicas de predicción.

Desde el punto de vista técnico, la demanda intermitente representa uno de los escenarios más complejos en el análisis de series de tiempo. La presencia de largos periodos sin consumo, combinada con picos esporádicos de alta magnitud, limita la capacidad explicativa de muchos modelos tradicionales y puede afectar el desempeño de arquitecturas de aprendizaje profundo cuando no se consideran las características propias de la serie. En este sentido, evaluar comparativamente distintos enfoques predictivos bajo condiciones reales de intermitencia resulta metodológicamente relevante y aporta claridad sobre la viabilidad de su aplicación en contextos industriales.

En el ámbito organizacional, la ausencia de modelos predictivos ajustados a la naturaleza de la demanda puede traducirse en decisiones ineficientes de reposición, exceso de inventario o riesgo de desabastecimiento de repuestos críticos. La implementación de un marco de análisis que clasifique los materiales según su nivel de intermitencia y determine el modelo más adecuado para cada caso permite reducir la incertidumbre operativa, optimizar el capital invertido en inventarios y fortalecer la planificación del mantenimiento.

Desde la perspectiva académica, este estudio contribuye al campo de la ciencia de datos aplicada al mantenimiento industrial al demostrar que la selección de modelos predictivos no debe realizarse de manera generalizada, sino en función de las condiciones estadísticas de la demanda. El principal aporte no radica únicamente en comparar métricas de desempeño, sino en establecer criterios técnicos que orienten la aplicabilidad de modelos estadísticos y de aprendizaje profundo en inventarios de repuestos con comportamiento irregular.

En consecuencia, la investigación es pertinente tanto por su impacto práctico en la gestión empresarial como por su aporte metodológico al análisis de demanda intermitente en entornos industriales, ofreciendo un enfoque replicable para organizaciones que enfrentan desafíos similares.

Objetivos

Objetivo General

Analizar y comparar el desempeño de distintos modelos predictivos aplicados a la demanda de repuestos en mantenimiento industrial, identificando las condiciones estadísticas bajo las cuales cada enfoque resulta metodológicamente adecuado en contextos de demanda intermitente.

Objetivos Específicos

Recolectar los datos históricos de consumo de repuestos registrados en el sistema SAP Business One para su estructuración y posterior análisis predictivo.

Depurar y transformar los datos recolectados con el fin de identificar patrones de consumo, frecuencia de demanda y niveles de intermitencia en cada material.

Realizar un análisis exploratorio de datos que permita caracterizar estadísticamente las series temporales mediante métricas como porcentaje de períodos sin demanda y coeficiente de variación.

Implementar y comparar distintos modelos predictivos, incluyendo enfoques estadísticos y arquitecturas de aprendizaje profundo, evaluando su desempeño mediante métricas como MAE, RMSE y R^2 para determinar su pertinencia según el comportamiento de la demanda.

Descripción del Problema

La gestión de inventarios de repuestos en mantenimiento industrial presenta una complejidad particular debido al comportamiento estadístico de su demanda. A diferencia de los productos comerciales, los repuestos industriales no siguen patrones de consumo regulares ni estacionales definidos; por el contrario, suelen presentar largos periodos sin consumo, intercalados con picos abruptos asociados a fallas o intervenciones correctivas. Este fenómeno, identificado en la literatura como demanda intermitente o errática, dificulta significativamente la aplicación de modelos tradicionales de pronóstico.

En el caso de Organización MAS S.A.S., la información histórica de consumo de repuestos se encuentra registrada en SAP Business One; sin embargo, no se ha realizado un análisis sistemático que permita caracterizar estadísticamente la demanda ni evaluar la viabilidad de distintos enfoques predictivos. Las decisiones relacionadas con reposición y niveles de inventario se fundamentan principalmente en criterios empíricos, lo cual puede conducir tanto a sobreabastecimiento como a desabastecimiento de componentes críticos.

El principal problema no radica únicamente en la ausencia de herramientas analíticas, sino en la falta de comprensión estructural del comportamiento de la demanda. Aplicar modelos de predicción sin considerar el nivel de intermitencia, variabilidad y frecuencia de consumo puede generar resultados inconsistentes y decisiones poco confiables. En este contexto, surge la necesidad de analizar rigurosamente las características estadísticas de las series temporales de consumo y determinar en qué condiciones es metodológicamente válido aplicar modelos predictivos en inventarios de mantenimiento.

Esta problemática plantea un reto tanto operativo como analítico: diseñar un enfoque que permita clasificar la demanda según su estructura y seleccionar el modelo predictivo más

adecuado para cada caso, reduciendo la incertidumbre en la planificación del inventario y fortaleciendo la toma de decisiones basada en datos.

Marco de Referencia

Gestión del Mantenimiento Industrial

La gestión del mantenimiento industrial es un componente estratégico en la administración de activos productivos, especialmente en entornos donde la disponibilidad operativa impacta directamente la productividad y los costos. Tradicionalmente, el mantenimiento se clasifica en correctivo, preventivo y predictivo, dependiendo del momento en que se realiza la intervención frente a la ocurrencia de fallas.

En los últimos años, la digitalización ha impulsado la transición hacia enfoques predictivos basados en datos históricos y análisis estadístico, permitiendo anticipar fallas y reducir tiempos de inactividad (Fractal, 2025). El mantenimiento predictivo utiliza información histórica y modelos analíticos para estimar comportamientos futuros, mejorando la planificación y asignación de recursos (Advanced Factories, 2024).

La norma ISO 55001 ha fortalecido la gestión estructurada de activos, promoviendo decisiones fundamentadas en datos y criterios técnicos (EVSA Group, 2025). En este contexto, la disponibilidad de repuestos se convierte en un factor crítico para la continuidad operativa, dado que su ausencia puede generar paradas no programadas con impacto económico significativo.

Gestión de Inventarios de Repuestos

La gestión de inventarios de repuestos presenta características diferenciadas frente a inventarios comerciales tradicionales. Estos materiales suelen registrar baja rotación, alta criticidad y demanda irregular, lo que dificulta la determinación de niveles óptimos de stock (EasyMaint, 2024).

La clasificación ABC permite segmentar repuestos según su impacto económico, mientras que el análisis XYZ evalúa la variabilidad de la demanda (Mint, 2023). Sin embargo,

estas herramientas son descriptivas y no abordan directamente el problema de la predicción futura en entornos de alta incertidumbre.

Estudios recientes en supply chain analytics destacan que los inventarios de repuestos requieren enfoques predictivos diferenciados debido a la presencia frecuente de demanda intermitente y eventos extremos (Syntetos & Boylan, 2023). Por ello, la integración de técnicas de series temporales y aprendizaje automático se ha convertido en una línea de investigación relevante en la gestión de inventarios industriales (Zucchetti, 2025).

Demanda Intermitente en Inventarios Industriales

La demanda intermitente se caracteriza por la existencia de múltiples períodos sin consumo intercalados con valores positivos irregulares. Este patrón es común en inventarios de mantenimiento industrial, donde el consumo depende de fallas no programadas y eventos operativos no periódicos.

La literatura reciente señala que la demanda intermitente representa uno de los mayores desafíos en forecasting debido a la alta proporción de ceros y la baja densidad de información estructurada (Forecasting Intermittent Demand with Machine Learning, 2025). En este contexto, la caracterización estadística previa resulta fundamental.

Las métricas más utilizadas para clasificar la intermitencia son:

- Average Demand Interval (ADI): mide el intervalo promedio entre demandas positivas.
- Coeficiente de variación (CV^2): mide la variabilidad relativa del tamaño de la demanda.

Estas métricas permiten categorizar las series en suaves, intermitentes, erráticas o altamente irregulares, facilitando la selección metodológica del modelo predictivo (Syntetos & Boylan, 2023).

Investigaciones recientes indican que aplicar modelos sin considerar previamente la estructura estadística de la demanda puede generar errores significativos y baja capacidad explicativa (Análisis predictivo con series temporales, 2025). Por ello, la clasificación estructural de la serie constituye una etapa metodológica indispensable.

Modelos Predictivos en Series Temporales

Los modelos de series temporales pueden agruparse en enfoques estadísticos tradicionales y modelos basados en aprendizaje automático.

Modelos Estadísticos

ARIMA (AutoRegressive Integrated Moving Average) es uno de los modelos clásicos en forecasting, diseñado para capturar dependencia temporal mediante componentes autorregresivos y de media móvil. Aunque ha demostrado solidez en series estructuradas, su desempeño puede deteriorarse en presencia de alta intermitencia (Análisis predictivo con series temporales, 2025).

Prophet, desarrollado por Meta, utiliza un enfoque aditivo que descompone la serie en tendencia y estacionalidad, permitiendo manejar cambios estructurales y datos faltantes con mayor robustez (Advanced Factories, 2024).

Modelos de Aprendizaje Profundo

Las redes neuronales recurrentes como LSTM (Long Short-Term Memory) y GRU (Gated Recurrent Unit) han demostrado capacidad para capturar dependencias temporales no lineales y patrones complejos en datos secuenciales. Estudios recientes muestran que estas

arquitecturas pueden superar modelos estadísticos cuando la serie presenta estructuras definidas o patrones repetitivos (Forecasting Intermittent Demand with Machine Learning, 2025).

La incorporación de mecanismos de atención permite ponderar dinámicamente los estados más relevantes dentro de la secuencia, mejorando la capacidad de ajuste en escenarios con variabilidad significativa.

No obstante, la literatura advierte que el desempeño de modelos deep learning depende del volumen y consistencia de los datos disponibles, siendo menos estables en series con información extremadamente dispersa (Zucchetti, 2025).

Métricas de Evaluación en Forecasting

La evaluación de modelos predictivos requiere métricas que permitan comparar precisión y estabilidad.

El MAE mide el error absoluto promedio y ofrece una interpretación directa en unidades reales. El RMSE penaliza con mayor peso los errores grandes, siendo especialmente relevante en series con picos abruptos (Análisis predictivo con series temporales, 2025).

El coeficiente R^2 evalúa la capacidad explicativa del modelo respecto a la variabilidad observada; sin embargo, en series altamente intermitentes puede presentar valores negativos cuando el modelo no supera una predicción promedio simple (Syntetos & Boylan, 2023).

Por ello, en contextos de demanda irregular se recomienda una evaluación comparativa multidimensional que considere simultáneamente distintas métricas y estabilidad global.

Sistema ERP y SAP Business One

Los sistemas ERP centralizan información operativa y permiten el registro histórico estructurado de movimientos de inventario y consumo de materiales (SAP, 2025). SAP Business

One ofrece funcionalidades específicas para el control de inventarios y mantenimiento, facilitando la trazabilidad de datos históricos (VisualK Group, 2024).

La disponibilidad de información consolidada constituye la base para la implementación de modelos predictivos, permitiendo transformar datos históricos en insumos analíticos para la toma de decisiones (Artero Consultores, 2023).

Metodología

La metodología empleada en este estudio se fundamenta en un enfoque cuantitativo aplicado, orientado a la caracterización estadística de la demanda de repuestos y a la evaluación comparativa de distintos modelos predictivos en un contexto de alta intermitencia.

El propósito no es implementar un sistema operativo de predicción, sino analizar el desempeño metodológico de diferentes enfoques estadísticos y de aprendizaje profundo aplicados a series temporales reales provenientes del área de mantenimiento de Organización MAS S.A.S.

El proceso metodológico se desarrolló en cinco etapas principales: preparación de datos, caracterización estadística, implementación de modelos, evaluación comparativa y análisis de pertinencia

Diseño General del Enfoque Metodológico

El estudio se desarrolla bajo un diseño no experimental, longitudinal y retrospectivo, utilizando datos históricos de consumo registrados en el sistema SAP Business One.

A partir de una base consolidada denominada “Base limpia.xlsx”, se construyeron series temporales mensuales por material. Sobre estas series se aplicaron distintos enfoques predictivos con el fin de:

- Analizar patrones de consumo.
- Identificar niveles de intermitencia y variabilidad.
- Evaluar la estabilidad predictiva de cada modelo.
- Comparar el desempeño mediante métricas cuantitativas.
- Los modelos evaluados incluyen:
- ARIMA.

- ARIMA + Red Neuronal.
- Prophet.
- CNN + LSTM.
- CNN + GRU + BiLSTM + Atención.
- La comparación se realizó bajo condiciones homogéneas de entrenamiento y

validación para garantizar consistencia en los resultados.

Preparación del Entorno y Librerías

El procesamiento de datos y entrenamiento de modelos se realizó en Google Colab, lo que permitió utilizar recursos de cómputo acelerado mediante GPU.

Se emplearon las siguientes librerías:

- Pandas y NumPy para limpieza, transformación y agregación de datos.
- Matplotlib para visualización de series temporales.
- Scikit-learn para escalamiento de datos y cálculo de métricas.
- pmdarima para la implementación automatizada de modelos ARIMA.
- Prophet para modelamiento aditivo de series temporales.
- TensorFlow y Keras para la construcción y entrenamiento de redes neuronales

profundas.

La integración con Google Drive permitió el almacenamiento estructurado de las bases depuradas, modelos entrenados y resultados generados.

Caracterización del Conjunto de Datos

Los datos utilizados fueron extraídos del sistema ERP SAP Business One, correspondiente al registro histórico de consumo de repuestos del área de mantenimiento industrial.

El periodo analizado comprende los años 2021 a 2025, lo que permitió disponer de una ventana temporal suficiente para identificar comportamientos de demanda.

Inicialmente se contaba con más de 100 materiales registrados en el sistema; sin embargo, para efectos del modelamiento predictivo se seleccionaron aquellos ítems que cumplían con los siguientes criterios:

- Historial mínimo de consumo.
- Registros consistentes sin vacíos estructurales.
- Frecuencia suficiente para construir series mensuales.

Después del filtrado, el análisis se concentró en 36 materiales.

Variabes consideradas

- Fecha de consumo.
- Descripción del material.
- Cantidad consumida.

Transformaciones aplicadas

- Eliminación de registros duplicados.
- Normalización de nombres de columnas.
- Conversión de fechas a formato datetime.
- Conversión de cantidades a valores numéricos.
- Agregación de consumo a frecuencia mensual.
- Imputación de meses sin consumo con valor cero.

Tabla 1*Características del Conjunto de Datos*

Característica	Descripción
Fuente de datos	SAP Business One
Empresa	Organización MAS S.A.S.
Periodo analizado	2021 – 2025
Frecuencia temporal	Mensual
Total, de datos analizados	2695
Materiales analizados	237
Tipo de datos	Series de tiempo
Variables principales	Fecha, Material, Cantidad consumida

Es importante señalar que los materiales incluidos en el análisis presentan diferencias significativas en sus unidades de medida y magnitudes de consumo, lo cual introduce variabilidad adicional en el proceso de modelamiento.

Algunos repuestos, como chumaceras, rodamientos, mangas y cuchillas, se contabilizan en unidades físicas, y su consumo mensual suele ser bajo, con valores discretos y frecuentemente cercanos a cero. En estos casos, la demanda se caracteriza por eventos esporádicos asociados a reemplazos específicos.

Por otro lado, materiales como aceites, activadores y pegantes se registran en gramos o kilogramos, y sus cantidades pueden ser considerablemente mayores debido a que se adquieren y consumen en presentaciones volumétricas, como cuñetes o envases industriales. Esto genera series con magnitudes numéricas significativamente superiores en comparación con los repuestos contados por unidad.

Esta heterogeneidad en escalas y unidades de medida implica que:

- Existen diferencias sustanciales en el rango de valores entre materiales.
- Las series presentan distintos niveles de dispersión.

Los modelos pueden verse afectados por la variabilidad de magnitud si no se aplican técnicas de normalización o escalamiento.

Por esta razón, fue necesario aplicar procesos de estandarización y escalamiento de datos antes del entrenamiento de los modelos predictivos, con el fin de garantizar estabilidad numérica y comparabilidad entre materiales.

Asimismo, esta diversidad estructural constituye un desafío adicional en la predicción, ya que la coexistencia de series discretas de baja frecuencia y series continuas de alta magnitud incrementa la complejidad del análisis y puede influir en el comportamiento de las métricas de evaluación.

Análisis de Datos

Con el fin de determinar el nivel de intermitencia de cada material, se calcularon las siguientes métricas:

- Porcentaje de períodos sin consumo (%Ceros).
- Average Demand Interval (ADI).
- Coeficiente de variación (CV^2).

Estas métricas permitieron clasificar las series temporales según su estructura de demanda y evaluar si existían condiciones suficientes para el entrenamiento de modelos predictivos.

Se identificó que la mayoría de los materiales presentan comportamiento intermitente o errático, caracterizado por alta proporción de meses sin consumo y picos de magnitud variable.

Esta etapa permitió justificar metodológicamente la comparación de distintos modelos bajo escenarios de alta variabilidad.

Análisis Exploratorio de Datos

Con el fin de comprender el comportamiento del consumo de repuestos y sustentar la selección de los modelos predictivos, se realizó un análisis exploratorio de datos (EDA) sobre las series temporales construidas a partir del historial de consumo mensual.

El análisis permitió identificar características comunes en los datos, tales como alta variabilidad, presencia de valores cero, consumo intermitente y picos asociados a eventos específicos de mantenimiento. Estas condiciones son típicas en inventarios de repuestos industriales y representan un desafío significativo para los modelos tradicionales de pronóstico.

La figura 1 presenta el consumo histórico mensual de algunos materiales representativos. En materiales como *Biela Excéntrica de Teflón 11310* y *Cuchilla Fija 11703* se observa un comportamiento relativamente estable, con patrones que permiten identificar tendencias y dependencias temporales. En contraste, otros materiales presentan un consumo irregular, caracterizado por largos periodos sin demanda y picos abruptos en determinados meses.

Adicionalmente, el análisis de la distribución del consumo evidenció una fuerte asimetría, con una alta concentración de valores bajos y pocos valores extremos, lo cual afecta directamente el desempeño de métricas basadas en error cuadrático y justifica el uso de enfoques robustos ante ruido y valores atípicos.


Este análisis exploratorio permitió concluir que el conjunto de datos no presenta una estacionalidad clara y uniforme para todos los materiales, sino comportamientos heterogéneos que requieren enfoques diferenciados. Por esta razón, se consideró pertinente evaluar tanto modelos estadísticos automatizados, como Prophet, que se adaptan bien a series irregulares,

como modelos de aprendizaje profundo, capaces de capturar patrones complejos en materiales con comportamiento más estructurado.

En consecuencia, el EDA sirvió como base fundamental para la selección y comparación de los modelos predictivos implementados, garantizando coherencia entre las características de los datos y las técnicas de modelamiento empleadas.

Figura 1

Consumos Históricos de Tela 10xxx



La figura anterior presenta el comportamiento histórico mensual del material Tela Cernido 10XXX (132 mc) durante el período analizado.

El eje horizontal representa el tiempo (fecha mensual), mientras que el eje vertical muestra la cantidad registrada en cada período. En esta serie se observan tanto valores positivos como negativos, los cuales corresponden a movimientos de inventario con distinta naturaleza:


- Valores positivos: indican ingresos al inventario, es decir, compras o reposiciones del material.
- Valores negativos: representan consumos o salidas del inventario asociadas a actividades de mantenimiento.

A lo largo de los años se evidencia un comportamiento variable, caracterizado por largos períodos sin movimiento intercalados con picos de ingreso o consumo. Este patrón confirma la presencia de demanda intermitente, donde los eventos no ocurren de manera regular ni siguen una estacionalidad definida.

Se observan algunos picos de ingreso significativos, que pueden estar asociados a compras por volumen o reposiciones estratégicas, mientras que los consumos suelen presentarse en magnitudes menores y de forma esporádica. Esta alternancia entre ingresos puntuales y consumos dispersos genera una serie temporal con alta variabilidad.

Figura 2

Consumos Históricos de Correa M49



La figura presenta el comportamiento mensual del material Correa M49 durante el período analizado.

Se observa que al inicio del año 2021 se registró un movimiento correspondiente a dos unidades. Posteriormente, la serie permanece en cero durante el resto del período evaluado, sin evidencia de nuevos consumos o ingresos significativos.

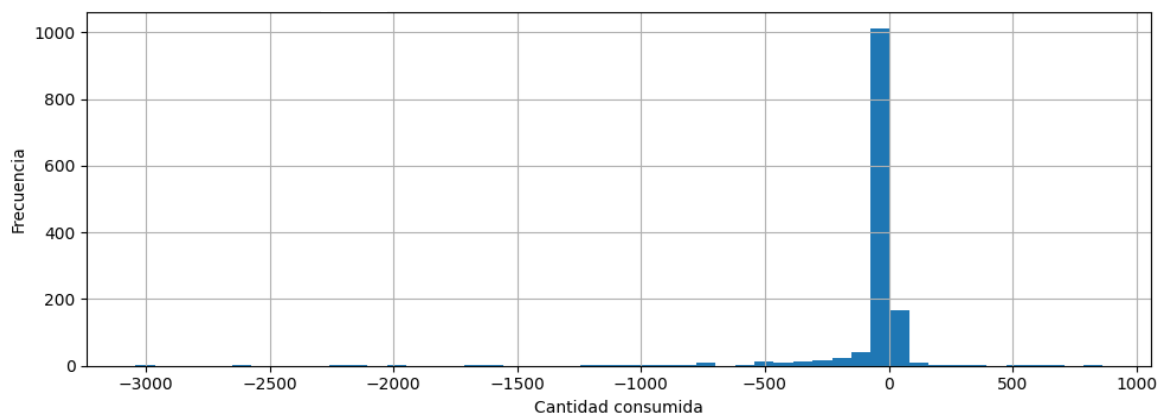
Este comportamiento refleja una demanda altamente intermitente con muy baja frecuencia, caracterizada por un único evento registrado y una prolongada ausencia de movimientos posteriores. Desde el punto de vista estadístico, la serie presenta:

- Alta proporción de períodos sin consumo.
- Insuficiente densidad de datos para identificar patrones.
- Ausencia de tendencia o estacionalidad observable.

En este contexto, la capacidad predictiva de los modelos se ve severamente limitada, ya que no existen suficientes observaciones para entrenar adecuadamente un modelo de series temporales. Técnicamente, este tipo de comportamiento puede clasificarse como una serie extremadamente esporádica, donde la predicción basada únicamente en el historial pierde robustez.

Adicionalmente, debe considerarse que el comportamiento futuro de este material no depende únicamente de su historial de consumo, sino también de decisiones operativas externas. Por ejemplo, la adquisición de una nueva máquina podría generar la necesidad de comprar más correas de este tipo para aumentar el nivel de inventario preventivo. Este tipo de evento no está contenido en la serie histórica y, por tanto, no puede ser anticipado por modelos puramente estadísticos.

Este caso evidencia una de las limitaciones centrales del forecasting en inventarios de mantenimiento: cuando la demanda es extremadamente baja o inexistente durante largos periodos, la predicción pierde confiabilidad y debe complementarse con criterios técnicos y decisiones operativas.

Figura 3*Distribución de Consumo Mensual de Repuestos*

La figura presenta la distribución de frecuencia de los valores de consumo mensual registrados en la base de datos consolidada.

Se observa una alta concentración de datos alrededor del valor cero, lo que indica que la mayoría de los períodos analizados no registran consumo significativo. Esta característica confirma la presencia de demanda intermitente, donde los eventos de consumo ocurren de forma esporádica y no continua.

Aunque la base de datos cuenta con 2.697 registros, la densidad informativa efectiva es limitada, debido a que gran parte de las observaciones corresponden a meses sin movimiento o con cantidades muy bajas. En términos estadísticos, esto genera:

- Distribución altamente asimétrica.
- Alta proporción de valores cero.
- Presencia de valores extremos (picos negativos y positivos).
- Baja regularidad temporal.

La acumulación de valores en cero reduce la capacidad de los modelos para identificar patrones consistentes, ya que la señal predictiva es débil frente al ruido y la dispersión. Además, la existencia de picos aislados incrementa la varianza de la serie, afectando métricas sensibles como el RMSE.

En consecuencia, aunque el volumen total de datos puede parecer suficiente en términos cuantitativos, la estructura de la distribución evidencia que la predicción resulta metodológicamente compleja. La calidad predictiva no depende únicamente del número de observaciones, sino de la regularidad y densidad de información contenida en la serie.

Este comportamiento justifica la necesidad de evaluar distintos enfoques predictivos y analizar su estabilidad frente a escenarios de alta intermitencia y dispersión.

Limpieza y Preparación de Datos

Antes de alimentar los modelos, se desarrolló un proceso de limpieza que incluyó:

Normalización de Nombres de Columnas

Se homogenizaron identificadores eliminando espacios, mayúsculas y tildes.

Esto redujo errores en la lectura del DataFrame.

Conversión de Fechas

Las columnas de fecha se transformaron usando `pd.to_datetime` con tratamiento de errores.

Conversión de Tipos de Datos

- La columna cantidad se convirtió a valores numéricos, reemplazando vacíos con cero.
- Se eliminaron caracteres extraños mediante normalización unicode.

Depuración de Registros

- Eliminación de datos duplicados.
- Restricción de datos incoherentes o fuera de rango.
- Consolidación de materiales con descripciones similares.

La base depurada se utilizó como insumo para todos los modelos.

Modelos Predictivos Implementados

Con el fin de evaluar el desempeño de distintos enfoques predictivos bajo condiciones de demanda intermitente, se implementaron cuatro modelos independientes.

Cada modelo fue entrenado y evaluado de manera individual para los 36 materiales analizados, con el objetivo de comparar su estabilidad y precisión frente a series con distintos niveles de variabilidad.

La comparación no busca identificar un modelo universalmente superior, sino analizar su comportamiento según la estructura de la demanda.

Modelo Híbrido CNN + LSTM

Este modelo combina redes convolucionales (CNN) con redes recurrentes LSTM para capturar patrones temporales en los datos.

El proceso inició con la organización de los datos en series mensuales por material. Posteriormente, se generaron secuencias temporales mediante ventanas deslizantes, lo que permite al modelo aprender relaciones entre períodos consecutivos.

La arquitectura utilizada incluye:

- Una capa Conv1D para identificar patrones locales.
- Una capa de max pooling para reducir ruido.
- Una capa LSTM para capturar dependencias de largo plazo.

- Capas densas finales para generar la predicción.

El entrenamiento se realizó con una división 80 % entrenamiento y 20 % validación, utilizando el optimizador Adam y la función de pérdida MSE.

Se aplicó escalamiento MinMaxScaler para mejorar la estabilidad numérica del entrenamiento.

El modelo generó predicciones tanto sobre el conjunto de prueba como para un horizonte futuro de 12 meses mediante un esquema autoregresivo.

Este enfoque resulta adecuado cuando la serie presenta cierto patrón temporal o comportamiento no lineal. Sin embargo, su desempeño depende de que exista suficiente información estructurada en la serie.

```
# PREDICCIÓN MULTIMATERIAL CON MODELO HÍBRIDO CNN + LSTM

!pip install unidecode tensorflow pandas numpy scikit-learn openpyxl

# IMPORTAR LIBRERÍAS Y CONECTAR DRIVE

from google.colab import drive

drive.mount('/content/drive')

import os

import numpy as np

import pandas as pd

import matplotlib.pyplot as plt

from sklearn.preprocessing import MinMaxScaler

import unidecode

from tensorflow.keras.models import Sequential

from tensorflow.keras.layers import Conv1D, MaxPooling1D, LSTM, Dropout, Dense
```

```

from tensorflow.keras.optimizers import Adam

#

# CARGAR Y LIMPIAR BASE

#

ruta "/content/drive/MyDrive/Colab ESP/Segundo Semestre/Proyecto de Grado II/Base
limpia.xlsx"

if not os.path.exists(ruta):

    raise FileNotFoundError(f"No se encontró el archivo en: {ruta}")

df = pd.read_excel(ruta)

print("✅ Archivo cargado correctamente.")

df.columns = [unicode.decode(c.strip().lower().replace(" ", "_")) for c in df.columns]

df.rename(columns={'fecha_de_contabilizacion': 'fecha_contabilizacion'}, inplace=True)

df['fecha_contabilizacion'] = pd.to_datetime(df['fecha_contabilizacion'], errors='coerce')

df['cantidad'] = pd.to_numeric(df['cantidad'], errors='coerce').fillna(0)

df.dropna(subset=['fecha_contabilizacion'], inplace=True)

df['año'] = df['fecha_contabilizacion'].dt.year

df['mes'] = df['fecha_contabilizacion'].dt.month

#

# AGRUPAR POR MES Y MATERIAL

#

df_mensual = (

    df.groupby(['descripcion', 'año', 'mes'], as_index=False)['cantidad']

    .sum()

```

```

        .sort_values(['descripcion', 'año', 'mes'])
    )

    print(f"Datos agrupados: {len(df_mensual)} filas, {df_mensual['descripcion'].nunique()}
materiales distintos")

#

# FUNCIÓN PARA CREAR SECUENCIAS

#

def crear_secuencias(serie, pasos6):

    X, y [], []

    for i in range(pasos, len(serie)):

        X.append(serie[i-pasos:i])

        y.append(serie[i])

    return np.array(X), np.array(y)

#

# DIRECTORIO DE RESULTADOS

#

dir_resultados "/content/drive/MyDrive/Colab ESP/Segundo Semestre/Proyecto de
Grado II/Predicciones"

os.makedirs(dir_resultados, exist_ok=True)

resultados []

#

# ENTRENAR UN MODELO POR MATERIAL

#

```

```

for material in df_mensual['descripcion'].unique():
    print(f"\n Entrenando modelo para: {material}")
    datos_mat = df_mensual[df_mensual['descripcion'] == material]['cantidad'].values
    if len(datos_mat) < 12:
        print(" Demasiados pocos datos. Se omite.")
        continue
    scaler = MinMaxScaler(feature_range=(-1, 1))
    datos_scaled = scaler.fit_transform(datos_mat.reshape(-1,1))
    X, y = crear_secuencias(datos_scaled, pasos6)
    X = X.reshape((X.shape[0], X.shape[1], 1))
    split = int(len(X)*0.8)
    X_train, X_test = X[:split], X[split:]
    y_train, y_test = y[:split], y[split:]
    model = Sequential([
        Conv1D(64, 2, activation='relu', input_shape=(6,1)),
        MaxPooling1D(pool_size=2),
        LSTM(128, return_sequences=False),
        Dropout(0.2),
        Dense(64, activation='relu'),
        Dense(1)
    ])
    model.compile(optimizer=Adam(learning_rate=0.001), loss='mse')

```

```

model.fit(X_train, y_train, epochs150, batch_size8, verbose0, validation_data(X_test,
y_test))

# Predicciones

pred model.predict(X_test, verbose0)

pred_inv scaler.inverse_transform(pred)

real_inv scaler.inverse_transform(y_test)

# Predicción futura (12 meses)

ultimos datos_scaled[-6:].reshape((1,6,1))

pred_futuro []

for _ in range(12):

    nuevo model.predict(ultimos, verbose0)

    pred_futuro.append(nuevo[0,0])

    nuevo_reshaped nuevo.reshape(1,1,1)

    ultimos np.concatenate((ultimos[:,1,:], nuevo_reshaped), axis1)

    pred_futuro_inv scaler.inverse_transform(np.array(pred_futuro).reshape(-
1,1)).flatten()

# Guardar resultados

meses_futuros pd.date_range(start'2025-11-01', periods12, freq'M')

df_pred pd.DataFrame({

    'Descripcion': material,

    'Fecha': meses_futuros,

    'Prediccion_Cantidad': pred_futuro_inv

})

```

```

resultados.append(df_pred)

# Graficar

plt.figure(figsize(10,4))

plt.plot(real_inv, label"Real")

plt.plot(pred_inv, 'o--', label"Predicción CNN+LSTM", color'orange')

plt.title(f"Validación - {material}")

plt.legend()

plt.savefig(os.path.join(dir_resultados, f"{material}_validacion.png"))

plt.close()

plt.figure(figsize(10,4))

plt.plot(datos_mat, label"Histórico")

plt.plot(range(len(datos_mat), len(datos_mat)+12), pred_futuro_inv, 'o--',
color'orange', label"Predicción 12M")

plt.title(f"Proyección futura - {material}")

plt.legend()

plt.savefig(os.path.join(dir_resultados, f"{material}_proyeccion.png"))

plt.close()

#

# GUARDAR TODAS LAS PREDICCIONES

#

df_resultados = pd.concat(resultados)

ruta_salida = os.path.join(dir_resultados, "Predicciones_CNN_LSTM_2025_2026.xlsx")

df_resultados.to_excel(ruta_salida, index=False)

```

```
print(f"\n Archivo guardado con todas las predicciones:\n{ruta_salida}")
print(" Gráficas individuales guardadas en la misma carpeta.")
```

Modelo CNN + GRU + BiLSTM + Atención

Este modelo es una arquitectura más compleja que combina varias capas para capturar distintos tipos de dependencias temporales.

La estructura incluye:

- Conv1D para detectar patrones locales.
- MaxPooling para reducción de dimensionalidad.
- GRU para dependencias de corto plazo.
- BiLSTM para dependencias bidireccionales.
- Mecanismo de atención para ponderar los estados más relevantes.
- Capas densas con regularización Dropout.

```
#
```

```
# MODELO CNN + GRU + BiLSTM + ATENCIÓN - POR MATERIAL
```

```
#
```

```
import os
```

```
import pandas as pd
```

```
import numpy as np
```

```
import matplotlib.pyplot as plt
```

```
from sklearn.preprocessing import MinMaxScaler
```

```
from sklearn.metrics import mean_absolute_error, mean_squared_error, r2_score
```

```
from tensorflow.keras.models import Model
```

```
from tensorflow.keras.layers import (
```

```

    Input, Dense, LSTM, GRU, Conv1D, MaxPooling1D, Flatten, Dropout,
    Bidirectional, Attention, Add, LayerNormalization
)

from tensorflow.keras.optimizers import Adam
from tensorflow.keras.regularizers import l2

#
# CONFIGURACIÓN GENERAL
#
ruta_base "/content/drive/MyDrive/Colab ESP/Segundo Semestre/Proyecto de Grado
II/Base limpia.xlsx"

salida "/content/drive/MyDrive/Colab ESP/Segundo Semestre/Proyecto de Grado
II/Predicciones"

os.makedirs(salida, exist_ok=True)

# Leer base

df pd.read_excel(ruta_base)

#
# NORMALIZACIÓN DE COLUMNAS
#

df.columns (
    df.columns
    .str.strip()
    .str.lower()
    .str.replace(" ", "_")

```

```

        .str.normalize('NFKD')
        .str.encode('ascii', errors='ignore')
        .str.decode('utf-8')
    )

    # Detectar columna de descripción y cantidad automáticamente
    col_desc [c for c in df.columns if 'desc' in c][0]
    col_cant [c for c in df.columns if 'cant' in c][0]

    # Detectar columna de fecha automáticamente
    col_fecha [c for c in df.columns if 'fecha' in c][0]

    # Convertir fecha
    df[col_fecha] pd.to_datetime(df[col_fecha], errors="coerce")
    df df.dropna(subset[col_fecha])

    df[col_cant] pd.to_numeric(df[col_cant], errors="coerce").fillna(0)

    #

    # FUNCIONES AUXILIARES

    #

    def crear_secuencias(datos, pasos):
        X, y [], []

        for i in range(len(datos) - pasos):
            X.append(datos[i:i+pasos])
            y.append(datos[i+pasos])

        return np.array(X), np.array(y)

    def modelo_avanzado(pasos):

```

```

inputs Input(shape(pasos, 1))

x Conv1D(64, kernel_size3, padding"same", activation"relu",
        kernel_regularizer12(0.001))(inputs)

x MaxPooling1D(pool_size2)(x)

x GRU(128, return_sequencesTrue)(x)

x Dropout(0.2)(x)

x Bidirectional(LSTM(128, return_sequencesTrue))(x)

x LayerNormalization()(x)

attn Attention()(x, x)

x Add()(x, attn)

x Flatten()(x)

x Dense(128, activation"relu")(x)

x Dropout(0.3)(x)

outputs Dense(1, activation"linear")(x)

model Model(inputs, outputs)

model.compile(optimizerAdam(learning_rate0.001), loss"mse", metrics["mae"])

return model

#

# ENTRENAR POR MATERIAL

#

materiales df[col_desc].unique()

pasos 6

horizonte 12

```

```

for material in materiales:

    print(f"\n Procesando material: {material}")

    data = df[df[col_desc] == material].copy().sort_values(col_fecha)

    if len(data) < pasos + 5:

        print(" Datos insuficientes, se omite este material.")

        continue

    # Suavizado y escalado

    scaler = MinMaxScaler()

    data["cantidad_suavizada"] = data[col_cant].ewm(alpha=0.3, adjust=False).mean()

    data["cantidad_scaled"] = scaler.fit_transform(data[["cantidad_suavizada"]])

    # Secuencias

    X, y = crear_secuencias(data["cantidad_scaled"].values, pasos)

    X = np.expand_dims(X, axis=1)

    n_train = int(len(X)*0.8)

    X_train, X_val = X[:n_train], X[n_train:]

    y_train, y_val = y[:n_train], y[n_train:]

    # Crear modelo

    modelo = modelo_avanzado(pasos)

    modelo.fit(

        X_train, y_train,

        validation_data=(X_val, y_val),

        epochs=200,

        batch_size=16,

```

```

    verbose0
)

# Validación

val_pred modelo.predict(X_val)

val_pred_inv scaler.inverse_transform(val_pred)

y_val_inv scaler.inverse_transform(y_val.reshape(-1,1))

mae mean_absolute_error(y_val_inv, val_pred_inv)

rmse np.sqrt(mean_squared_error(y_val_inv, val_pred_inv))

r2 r2_score(y_val_inv, val_pred_inv)

print(f" MAE: {mae:.2f} | RMSE: {rmse:.2f} | R²: {r2:.4f}")

# Predicción futura

ultimos data["cantidad_scaled"].values[-pasos:].reshape(1, pasos, 1)

pred_futuro []

for _ in range(horizonte):

    nuevo modelo.predict(ultimos, verbose0)

    pred_futuro.append(nuevo[0,0])

    ultimos np.concatenate([ultimos[:,1:,:], nuevo.reshape(1,1,1)], axis1)

pred_futuro_inv scaler.inverse_transform(np.array(pred_futuro).reshape(-1,1))

# Guardar resultados

fechas_futuras pd.date_range(data[col_fecha].max() + pd.offsets.MonthEnd(1),
                             periodshorizonte, freq'M')

df_resultados pd.DataFrame({
    "Material": material,

```

```

    "Mes_Futuro": fechas_futuras,
    "Predicción": pred_futuro_inv.flatten(),
    "MAE": mae,
    "RMSE": rmse,
    "R²": r2
})

ruta_excel f"{salida}/Prediccion_{material.replace(' ', '_')}.xlsx"
df_resultados.to_excel(ruta_excel, index=False)
print(f" Archivo guardado: {ruta_excel}")

# Gráfica
plt.figure(figsize(9,4))
plt.plot(data[col_fecha], data[col_cant], label"Histórico", color"blue")
plt.plot(fechas_futuras, pred_futuro_inv, '--o', label"Predicción 12M", color"orange")
plt.title(f"Predicción CNN + GRU + BiLSTM + Atención - {material}")
plt.xlabel("Fecha")
plt.ylabel("Cantidad")
plt.legend()
plt.grid(True)
plt.tight_layout()
ruta_png f"{salida}/{material.replace(' ', '_')}_grafica.png"
plt.savefig(ruta_png)
plt.close()
print(f" Gráfica guardada: {ruta_png}")

```

```
print("\n Proceso finalizado para todos los materiales.")
```

Cada material fue procesado de forma independiente.

El entrenamiento se realizó durante 200 épocas con partición 80-20 y función de pérdida MSE.

La predicción a 12 meses se realizó de forma autoregresiva, utilizando cada valor estimado como entrada para el siguiente período.

Este modelo tiene mayor capacidad para capturar patrones complejos. Sin embargo, al ser más profundo, puede volverse inestable cuando la serie tiene demasiados valores cero o información limitada.

Modelo Prophet (Meta/Facebook)

Prophet es un modelo estadístico automatizado diseñado para series temporales con tendencia y posibles cambios estructurales.

Para su implementación:

- Se consolidaron las series mensuales por material.
- Se completaron meses sin consumo con valor cero.
- Se activó estacionalidad anual.
- Se desactivaron componentes diarios y semanales.

Prophet descompone la serie en tendencia y estacionalidad, generando automáticamente proyecciones futuras.

Se entrenó un modelo independiente por material y se generaron predicciones a 12 meses.

Las métricas MAE, RMSE y R^2 permitieron evaluar el ajuste histórico y la estabilidad del modelo.

Este enfoque tiende a comportarse de manera más estable en series con alta variabilidad o pocos datos, aunque puede no capturar adecuadamente patrones muy irregulares.

```
#  
  
# Predicción de consumo con Meta Prophet  
  
# Basado en tu archivo "Base limpia.xlsx"  
  
#  
  
!pip install prophet openpyxl --quiet  
  
import pandas as pd  
  
import numpy as np  
  
import os  
  
from prophet import Prophet  
  
import matplotlib.pyplot as plt  
  
from sklearn.metrics import mean_absolute_error, mean_squared_error  
  
from math import sqrt  
  
import re  
  
# CONFIGURACIÓN  
  
ruta_excel "/content/drive/MyDrive/Colab ESP/Segundo Semestre/Proyecto de Grado  
II/Base limpia.xlsx"  
  
carpeta_salida "/content/drive/MyDrive/Colab ESP/Segundo Semestre/Proyecto de  
Grado II/Predicciones_Prophet"  
  
os.makedirs(carpeta_salida, exist_ok=True)  
  
# CARGA Y LIMPIEZA  
  
df pd.read_excel(ruta_excel)  
  
df.columns df.columns.str.lower().str.strip().str.replace(" ", "_")  
  
# Normalización por si hay tildes
```

```

df.columns df.columns.str.normalize('NFKD').str.encode('ascii',
errors'ignore').str.decode('utf-8')

# Asegurar nombres consistentes

col_desc [c for c in df.columns if 'descripcion' in c][0]
col_cant [c for c in df.columns if 'cantidad' in c][0]

# Usar fecha de contabilización si existe, si no usar fecha del sistema
if 'fecha_de_contabilizacion' in df.columns:
    col_fecha 'fecha_de_contabilizacion'
elif 'fecha_contabilizacion' in df.columns:
    col_fecha 'fecha_contabilizacion'
elif 'fecha_del_sistema' in df.columns:
    col_fecha 'fecha_del_sistema'
else:
    raise ValueError("No se encontró ninguna columna de fecha válida.")

# Crear DataFrame base
df df[[col_desc, col_fecha, col_cant]].rename(columns{
    col_desc: 'descripcion',
    col_fecha: 'fecha',
    col_cant: 'cantidad'
})

# Convertir fechas
df['fecha'] pd.to_datetime(df['fecha'], errors'coerce')
df df.dropna(subset['fecha'])

```

```

df['cantidad'].fillna(0)

# INICIO DE PREDICCIÓN

resultados []

for material, grupo in df.groupby('descripcion'):

    grupo = grupo.sort_values('fecha')

    if len(grupo) < 3 or grupo['cantidad'].sum() == 0:

        print(f" Se omite {material}: pocos datos o sin consumo.")

        continue

    # Agrupar por mes

    datos = grupo.groupby(pd.Grouper(key='fecha', freq='M'))['cantidad'].sum().reset_index()

    # Estructura Prophet

    datos = datos.rename(columns={'fecha': 'ds', 'cantidad': 'y'})

    # Asegurar frecuencia mensual continua

    datos = datos.set_index('ds').asfreq('M', fill_value=0).reset_index()

    # --- Entrenamiento Prophet ---

    modelo = Prophet(yearly_seasonality=True, weekly_seasonality=False,
daily_seasonality=False)

    modelo.fit(datos)

    # Predicción futura (12 meses)

    futuro = modelo.make_future_dataframe(periods=12, freq='M')

    forecast = modelo.predict(futuro)

    # Evaluación

    y_true = datos['y']

```

```

y_pred forecast['yhat'][:len(y_true)]
mae mean_absolute_error(y_true, y_pred)
rmse sqrt(mean_squared_error(y_true, y_pred))
r2 np.corrcoef(y_true, y_pred)[0,1]**2 if len(y_true) > 1 else np.nan
forecast['Material'] material
forecast['MAE'] mae
forecast['RMSE'] rmse
forecast['R2'] r2
resultados.append(forecast)
# --- Gráfico individual ---
nombre_archivo re.sub(r'^a-zA-Z0-9_()ÑáéíóúÁÉÍÓÚ', '_', material)
plt.figure(figsize(10,5))
plt.plot(datos['ds'], datos['y'], 'bo-', label'Histórico')
plt.plot(forecast['ds'], forecast['yhat'], 'r--', label'Predicción 12M')
plt.title(f"Predicción de consumo - {material}")
plt.xlabel("Fecha")
plt.ylabel("Cantidad")
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.savefig(os.path.join(carpetas_salida, f"{nombre_archivo}_prophet.png"))
plt.close()
# CONSOLIDAR RESULTADOS

```

if resultados:

```
df_final pd.concat(resultados, ignore_index=True)
```

```
ruta_salida_excel os.path.join(carpeta_salida, "Predicciones_Prophet_Global.xlsx")
```

```
df_final.to_excel(ruta_salida_excel, index=False)
```

```
print(f" Archivo global generado con éxito: {ruta_salida_excel}")
```

else:

```
print(" No se generaron predicciones válidas. ")
```

Modelo ARIMA + Red Neuronal

Este modelo combina un enfoque estadístico clásico con una red neuronal.

Primero se ajustó un modelo ARIMA utilizando `auto_arima`, considerando estacionalidad anual ($m = 12$).

ARIMA modela la parte lineal y estructurada de la serie.

Luego se calcularon los residuos (diferencia entre valor real y estimado).

Estos residuos fueron utilizados como entrada para una red neuronal densa de tres capas, que aprende patrones no lineales no capturados por ARIMA.

Finalmente, las predicciones futuras se obtuvieron sumando:

- La proyección ARIMA.
- La estimación de residuos generada por la red neuronal.

Este modelo busca aprovechar la interpretación estadística de ARIMA y la flexibilidad de las redes neuronales.

Su desempeño depende de que exista una estructura parcialmente lineal que pueda ser capturada en la primera etapa.

```
#  
  
# MODELO HÍBRIDO FINAL ARIMA + RED NEURONAL (LIMPIO)  
  
#  
  
!pip install pmdarima tensorflow openpyxl --quiet  
  
import pandas as pd  
  
import numpy as np  
  
import os, re, warnings  
  
import matplotlib.pyplot as plt  
  
from sklearn.metrics import mean_absolute_error, mean_squared_error  
  
from math import sqrt  
  
from tensorflow.keras.models import Sequential  
  
from tensorflow.keras.layers import Dense  
  
from tensorflow.keras.optimizers import Adam  
  
from pmdarima import auto_arima  
  
warnings.filterwarnings("ignore")  
  
# CONFIGURACIÓN  
  
ruta_excel "/content/drive/MyDrive/Colab ESP/Segundo Semestre/Proyecto de Grado  
II/Base limpia.xlsx"  
  
carpeta_salida "/content/drive/MyDrive/Colab ESP/Segundo Semestre/Proyecto de  
Grado II/Predicciones_ARIMA_NN"  
  
os.makedirs(carpeta_salida, exist_ok=True)  
  
# CARGAR DATOS  
  
df pd.read_excel(ruta_excel)
```

```

df.columns df.columns.str.lower().str.strip().str.replace(" ", "_")
df.columns df.columns.str.normalize('NFKD').str.encode('ascii',
errors'ignore').str.decode('utf-8')

# Detectar columnas
col_desc [c for c in df.columns if 'descripcion' in c][0]
col_cant [c for c in df.columns if 'cantidad' in c][0]
col_fecha [c for c in df.columns if 'fecha' in c and 'contabilizacion' in c]
if col_fecha:
    col_fecha col_fecha[0]
else:
    col_fecha [c for c in df.columns if 'fecha' in c][0]

# Renombrar
df df[[col_desc, col_fecha, col_cant]].rename(columns{
    col_desc: 'descripcion',
    col_fecha: 'fecha',
    col_cant: 'cantidad'
})

# Convertir fechas y limpiar
df['fecha'] pd.to_datetime(df['fecha'], errors'coerce')
df['cantidad'] pd.to_numeric(df['cantidad'], errors'coerce').fillna(0)
df df.dropna(subset['fecha'])

# MODELO POR MATERIAL
resultados []

```

```

for material, grupo in df.groupby('descripcion'):

    grupo = grupo.sort_values('fecha')

    if len(grupo) < 6 or grupo['cantidad'].sum() == 0:

        print(f" {material} omitido: pocos datos o todo en cero.")

        continue

    # Agrupar mensual

    serie = grupo.groupby(pd.Grouper(key='fecha', freq='M'))['cantidad'].sum()

    serie = serie.asfreq('M', fill_value=0).fillna(0)

    # Eliminar posibles infinitos

    serie.replace([np.inf, -np.inf], 0, inplace=True)

    # MODELO ARIMA

    try:

        modelo_arima = auto_arima(

            serie, seasonal=True, m12,

            suppress_warnings=True, stepwise=True, trace=False

        )

        pred_arima = modelo_arima.predict_in_sample()

        residuales = (serie - pred_arima)

    except Exception as e:

        print(f" ARIMA falló en {material}: {e}")

        continue

    # LIMPIEZA DE RESIDUALES

    residuales = pd.Series(residuales).replace([np.inf, -np.inf, np.nan], 0)

```

```

if residuales.isna().any():
    residuales = residuales.fillna(0)

# RED NEURONAL (ajuste de residuales)
X = np.arange(len(residuales)).reshape(-1, 1)
y = residuales.values

model_nn = Sequential([
    Dense(32, activation='relu', input_dim=1),
    Dense(16, activation='relu'),
    Dense(1)
])

model_nn.compile(optimizer=Adam(learning_rate=0.01), loss='mse')
model_nn.fit(X, y, epochs=100, verbose=0)

# PREDICCIÓN FUTURA
try:
    futuro_arima = modelo_arima.predict(n_periods=12)
    futuro_arima = np.nan_to_num(futuro_arima, nan=0.0, posinf=0.0, neginf=0.0)
except Exception as e:
    print(f"Error al predecir con ARIMA en {material}: {e}")
    continue

# Construir entradas futuras
X_future = np.arange(len(residuales), len(residuales) + 12).reshape(-1, 1)
X_future = np.nan_to_num(X_future)

try:

```

```

future_residuals model_nn.predict(X_future, verbose=0).flatten()

future_residuals np.nan_to_num(future_residuals, nan=0.0, posinf=0.0, neginf=0.0)

except Exception as e:

    print(f" Error al predecir residuales con red neuronal en {material}: {e}")

    continue

# Combinar ambas predicciones

pred_total futuro_arima + future_residuals

# Validar resultado

if np.isnan(pred_total).any():

    print(f" {material} omitido: predicción final contiene NaN.")

    continue

# EVALUACIÓN

mae mean_absolute_error(serie, pred_arima)

rmse sqrt(mean_squared_error(serie, pred_arima))

r2 np.corrcoef(serie, pred_arima)[0,1]**2 if len(serie) > 1 else np.nan

# Guardar resultados

fechas_futuras pd.date_range(serie.index[-1] + pd.offsets.MonthEnd(1), periods=12,

freq='M')

df_pred pd.DataFrame({

    'fecha': fechas_futuras,

    'prediccion_arima_nn': pred_total,

    'Material': material,

    'MAE': mae,

```

```

    'RMSE': rmse,
    'R2': r2
})

resultados.append(df_pred)

# GRAFICAR

nombre_archivo = re.sub(r'^[a-zA-Z0-9_]{1,100}$', '_', material)

plt.figure(figsize=(10,5))

plt.plot(serie.index, serie.values, 'bo-', label='Histórico')

plt.plot(fechas_futuras, pred_total, 'r--o', label='Predicción (ARIMA+NN)')

plt.title(f"Predicción híbrida ARIMA+NN - {material}")

plt.xlabel("Meses")

plt.ylabel("Cantidad")

plt.legend()

plt.grid(True)

plt.tight_layout()

plt.savefig(os.path.join(carpetas_salida, f"{nombre_archivo}_ARIMA_NN.png"))

plt.close()

# GUARDAR RESULTADOS GLOBALES

if resultados:

    df_final = pd.concat(resultados, ignore_index=True)

    ruta_salida_excel = os.path.join(carpetas_salida,

"Predicciones_ARIMA_NN_Global.xlsx")

    df_final.to_excel(ruta_salida_excel, index=False)

```

```
print(f" Archivo global guardado: {ruta_salida_excel}")
```

```
else:
```

```
print(" No se generaron predicciones válidas.")
```

Resultados

El proceso de modelamiento permitió evaluar comparativamente cuatro enfoques predictivos aplicados al consumo mensual de repuestos:

- ARIMA + Red Neuronal
- CNN + LSTM
- CNN + GRU + BiLSTM + Atención
- Prophet

La evaluación se realizó utilizando tres métricas estándar en series temporales:

- MAE (Mean Absolute Error)
- RMSE (Root Mean Square Error)
- R^2 (Coeficiente de determinación)

Las métricas se calcularon individualmente para cada uno de los 36 materiales analizados. Posteriormente, se obtuvieron promedios globales por modelo, lo que permitió identificar tendencias generales y comparar su comportamiento bajo condiciones de alta intermitencia.

Comparación General de Desempeño

La Figura 4 presenta el MAE promedio por modelo.

Se observa que los valores son relativamente cercanos entre sí. Prophet obtiene el menor MAE promedio, seguido por ARIMA + NN y los modelos basados en deep learning.

El MAE mide el error absoluto promedio en las mismas unidades de la variable, por lo que permite interpretar de manera directa la magnitud del error. Sin embargo, la diferencia entre modelos no es amplia, lo que indica que esta métrica por sí sola no permite establecer una superioridad concluyente.

En series altamente intermitentes, el MAE puede verse influenciado por la alta proporción de valores cero, reduciendo su capacidad discriminadora entre modelos.

Comparación del RMSE

La Figura 5 muestra el RMSE promedio por modelo.

A diferencia del MAE, el RMSE penaliza con mayor intensidad los errores grandes, por lo que es más sensible a picos extremos o variaciones abruptas.

En esta métrica se observa que:

- ARIMA + NN presenta el mayor RMSE promedio (aproximadamente 30), lo que indica mayor sensibilidad a valores atípicos.
- CNN + GRU + BiLSTM + Atención y CNN + LSTM presentan valores similares (entre 18 y 19).
- Prophet registra el menor RMSE promedio.

Estos resultados sugieren que Prophet mantiene mayor estabilidad frente a series con alta dispersión y picos aislados, mientras que el modelo híbrido ARIMA + NN muestra mayor variabilidad en su ajuste.

Comparación del Coeficiente R^2

La Figura 6 presenta el R^2 promedio por modelo.

En este caso se observa que:

- Prophet es el único modelo con R^2 promedio positivo.
- Los modelos CNN + GRU + BiLSTM + Atención y CNN + LSTM presentan valores promedio negativos.
- ARIMA + NN se mantiene cercano a cero, pero por debajo de Prophet.

En contextos de demanda intermitente, valores negativos de R^2 no son inusuales, ya que la alta proporción de períodos sin consumo dificulta que el modelo supere una predicción promedio simple.

El R^2 positivo de Prophet indica que, en promedio, logra explicar una mayor proporción de la variabilidad histórica frente a los demás modelos.

Análisis Comparativo Consolidado

La Tabla 1 presenta el ranking general de cada modelo en función de su posición relativa en MAE, RMSE y R^2 .

Tabla 2

Ranking Comparativo de Modelos Predictivos

Modelo	MAE_Rank	RMSE_Rank	R^2 _Rank
ARIMA + NN	2.0	4.0	2.0
CNN + GRU + BiLSTM +Atencion	3.5	2.5	3.5
CNN + LSTM	3.5	2.5	3.5
Prophet	1.0	1.0	1.0

Prophet obtiene el mejor desempeño global al ocupar la primera posición en las tres métricas consideradas.

No obstante, la diferencia entre modelos no es uniforme en todos los materiales, lo que sugiere que el comportamiento depende de la estructura particular de cada serie.

Interpretación global de los resultados

El análisis conjunto de métricas y comportamientos individuales permite identificar varios hallazgos relevantes.

Estabilidad de Prophet

Prophet muestra mayor estabilidad promedio en escenarios de alta intermitencia.

- Presenta el menor MAE y RMSE.
- Es el único modelo con R^2 promedio positivo.
- Maneja adecuadamente series con múltiples valores cero y cambios abruptos.

Esto indica que su estructura aditiva y automatizada se adapta mejor a datos con irregularidad significativa.

Desempeño de Modelos Neuronales en Series Estructuradas

El modelo CNN + GRU + BiLSTM + Atención presenta resultados destacados en materiales con patrones temporales más definidos.

Ejemplos específicos incluyen:

- Biela Excéntrica de Teflón 11310 $\rightarrow R^2 = 0.824$
- Cuchilla Fija 11703 $\rightarrow R^2 = 0.664$

En estos casos, la arquitectura profunda logra capturar dependencias temporales más complejas que los modelos estadísticos.

Limitaciones en Series Altamente Irregulares

En materiales con consumo extremadamente esporádico, como aceites, correas o consumibles de baja frecuencia, los modelos neuronales presentan R^2 negativos debido a la escasez de estructura temporal.

Este comportamiento es consistente con la literatura sobre demanda intermitente, donde la ausencia de patrones repetitivos limita la capacidad de aprendizaje de modelos complejos.

Ausencia de un Modelo Universal

Los resultados confirman que no existe un modelo único que sea óptimo para todos los materiales.

En términos generales:

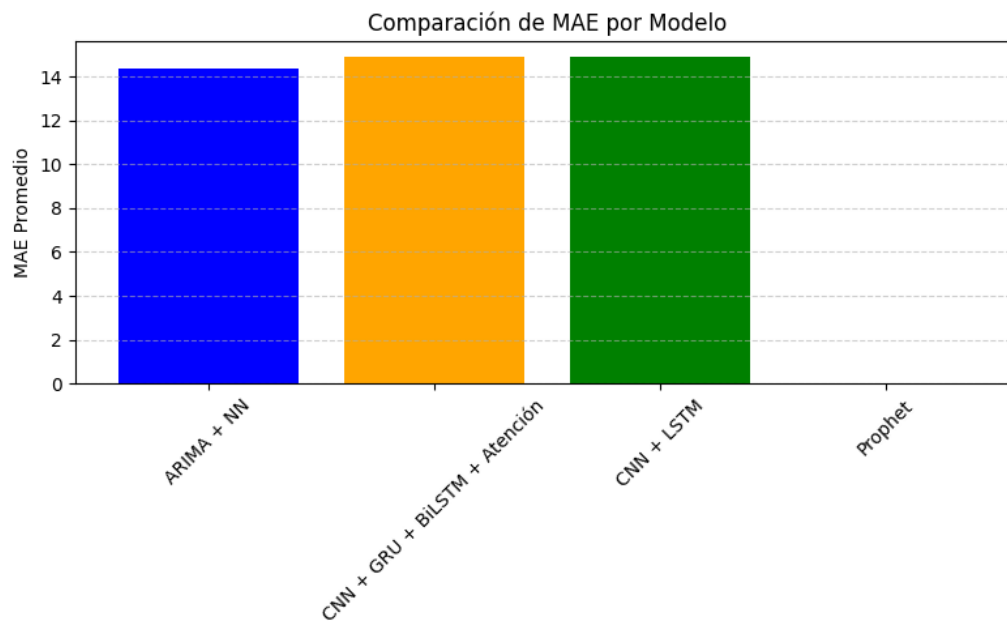
- Aproximadamente el 70 % de los materiales presentan consumo errático.
- Un 20 % muestra cierta regularidad.
- Un 10 % presenta patrones más definidos.

En consecuencia, la pertinencia del modelo depende directamente de la estructura estadística de la serie.

Visualización Comparativa Multidimensional

Figura 4


Comparación del MAE Promedio por Modelo



La gráfica muestra la comparación del MAE promedio obtenido por cada modelo predictivo. Se observa que los valores son similares entre los distintos enfoques, lo que indica que, en términos de error absoluto promedio, ninguno presenta una diferencia considerable frente a los demás. Prophet registra el menor MAE, lo que sugiere un ajuste ligeramente más preciso en promedio. Sin embargo, la proximidad de los valores evidencia que esta métrica, por sí sola, no permite establecer una superioridad concluyente entre modelos.

Figura 5

Comparación del RMSE Promedio por Modelo

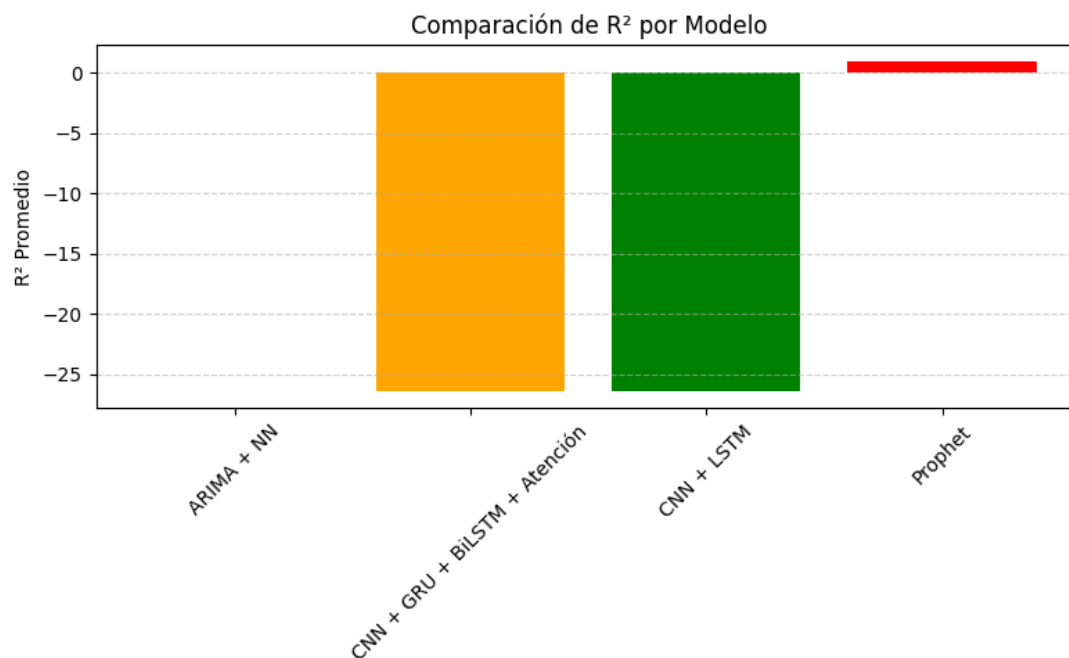


La gráfica presenta la comparación del RMSE promedio entre los modelos evaluados. A diferencia del MAE, esta métrica penaliza con mayor peso los errores grandes, por lo que permite identificar qué modelo es más sensible a valores extremos. Se observa que ARIMA + NN presenta el mayor RMSE, lo que indica una mayor variabilidad en sus predicciones. Por su parte, los modelos basados en redes neuronales profundas muestran valores intermedios,

mientras que Prophet registra el menor RMSE promedio, evidenciando mayor estabilidad frente a picos o fluctuaciones abruptas en la serie.

Figura 6

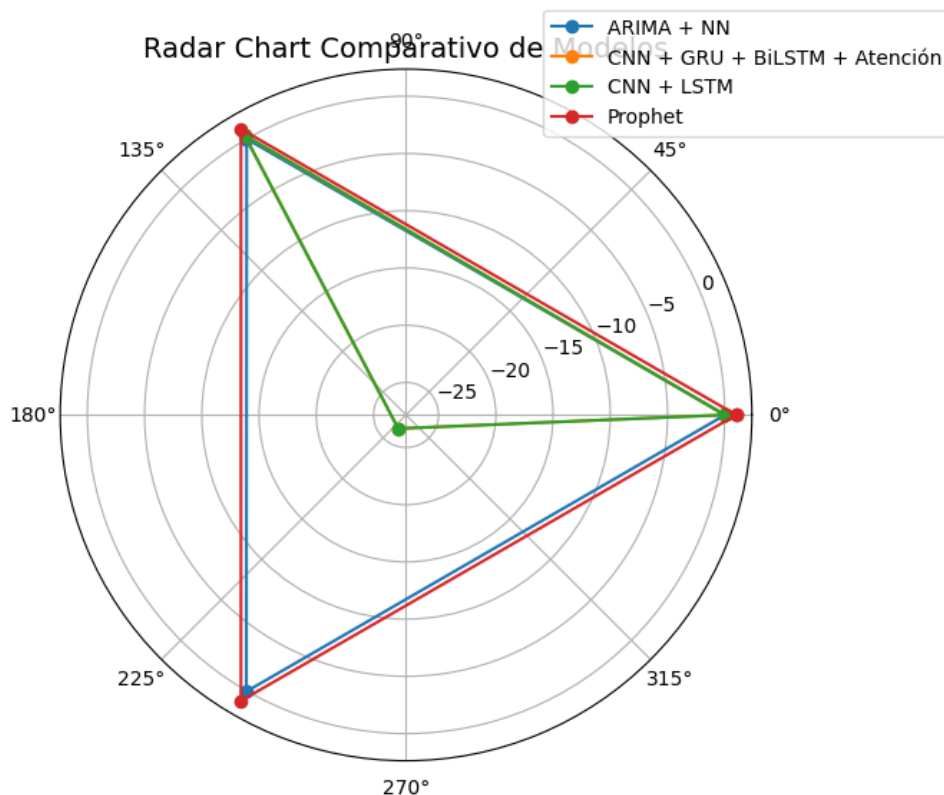
Comparación del R^2 Promedio por Modelo



La gráfica muestra la comparación del coeficiente R^2 promedio para cada modelo. En este caso, se observa que Prophet es el único modelo que obtiene un valor positivo, lo que indica una mejor capacidad para explicar la variabilidad histórica de la serie. Los modelos basados en redes neuronales presentan valores promedio negativos, situación que puede ocurrir en series altamente intermitentes o con gran presencia de valores cero, donde el modelo no logra superar una predicción promedio simple. Estos resultados reflejan la dificultad de modelar consumos irregulares y evidencian diferencias en la capacidad explicativa de cada enfoque.

Figura 7

Radar Chart Comparativo de Modelos



Comparación multidimensional de desempeño para los modelos ARIMA+NN, CNN+LSTM, CNN+GRU+BiLSTM+Atención y Prophet, considerando MAE, RMSE y R^2 promedio.

La figura presenta una comparación multidimensional del desempeño de los modelos evaluados, considerando simultáneamente las métricas MAE, RMSE y R^2 promedio. Esta visualización permite analizar de forma integrada la precisión y la capacidad explicativa de cada enfoque.

Se observa que Prophet mantiene un comportamiento más equilibrado entre las tres métricas, lo que confirma su mayor estabilidad en escenarios con alta variabilidad e

intermitencia. Por su parte, el modelo CNN + GRU + BiLSTM + Atención muestra un desempeño competitivo, especialmente en materiales con patrones más definidos, aunque presenta mayor variabilidad en series altamente esporádicas.

En conjunto, los resultados evidencian que no existe un modelo óptimo para todos los materiales. La pertinencia del enfoque predictivo depende directamente de la estructura estadística de la demanda, lo que respalda la necesidad de seleccionar el modelo según el comportamiento histórico de cada repuesto.

Clasificación de Materiales Según Viabilidad Predictiva

Con el fin de determinar de manera objetiva qué materiales presentan condiciones adecuadas para la aplicación de modelos predictivos, se desarrolló un procedimiento de clasificación basado en métricas estructurales de la demanda.

- Para cada material se calcularon los siguientes indicadores:
- Número total de meses observados.
- Número de meses con consumo positivo.
- Porcentaje de períodos sin consumo (%Ceros).
- Coeficiente de variación (CV).
- Average Demand Interval (ADI).

Con base en estos indicadores se definieron criterios de viabilidad predictiva bajo tres niveles:

Predictible (suficiente historial):

- Al menos 12 meses con consumo positivo.
- $\%Ceros \leq 85 \%$.
- $ADI \leq 8$.

Moderada (predictible con limitaciones):

- Al menos 6 meses con consumo positivo.
- %Ceros \leq 93 %.

Alta intermitencia (no predictable):

- No cumple los criterios anteriores.

Este esquema permitió evaluar la suficiencia informativa de cada serie antes de aplicar modelos complejos.

Tabla 3

Clasificación de Materiales Según Nivel de Intermitencia y Predictibilidad

Material	Meses	Meses con consumo	%Ceros	CV	AD I	Clasificación
Aceite 50 x 5 Gl	21	0	0.61 9	inf	inf	Alta intermitencia (no predictable)
Aceite 50 x Caneca 5 gal	35	4	0.65 7	inf	5.3 33	Alta intermitencia (no predictable)
Aceite Beg Speed Gear 250 x Galón	35	3	0.62 9	inf	12	Alta intermitencia (no predictable)
Aceite Beg Speed Gear GL-5 #250 Galón	20	3	0.7	inf	9.5	Alta intermitencia (no predictable)
Aceite Compresores Roto Synthetic Fluid Xtend Duty x 5L	37	5	0.64 9	inf	4.7 5	Alta intermitencia (no predictable)
Aceite Hidraulico Begax	14	2	0.64 3	4.7 27	5	Alta intermitencia (no predictable)
Aceite Hidraulico Begax x Galón	38	2	0.44 7	inf	36	Alta intermitencia (no predictable)
Aceite Penetrante x 20 Onz	51	2	0.88 2	inf	32	Alta intermitencia (no predictable)

Material	Meses	Meses con consumo	%C eros	CV	AD I	Clasificación
Aceite Premium Reductores x 5 Gl	25	2	0.8	inf	23	Alta intermitencia (no predictable)
Aceite Premium Reductores x Caneca 5 gal	37	5	0.35 1	inf	8.5	Alta intermitencia (no predictable)
Aceite UMP 495 TM x 1 Gl	25	2	0.88	inf	23	Alta intermitencia (no predictable)
Aceite UMP 495 TM x Galón	38	2	0.42 1	inf	11	Alta intermitencia (no predictable)
Activador Ultrafix 160 g	43	6	0.11 6	inf	7.6	Moderada (predictible con limitaciones)
Arrancador Suave 3RW3037-1BB14 (63A)	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Arrancador Suave 3RW4028-1BB14 (38A)	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Arrancador Suave 3RW4037-1BB14 (63A)	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Arrancador Suave 3RW4047-1BB14 (106A)	16	1	0.87 5	inf	inf	Alta intermitencia (no predictable)
Arrancador Suave 3RW5534-6HA14 (30HP)	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Banda Plana 1040 mm x 25 mm	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Banda Plana 1160 mm x 25 mm	17	1	0.88 2	9.1 65	inf	Alta intermitencia (no predictable)
Banda Plana 1350 mm x 25 mm	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)

Material	Meses	Meses con consumo	%C eros	CV	AD I	Clasificación
Banda Plana 1370 mm x 25 mm	17	1	0.88 2	4.5 59	inf	Alta intermitencia (no predecible)
Bases de Relevado GZT4-SZARE	27	3	0.81 5	4.7 35	4.5	Alta intermitencia (no predecible)
Biela Excentrica de Teflon 11310	38	6	0.60 5	16. 79	6.8	Moderada (predecible con limitaciones)
Bloque Alimentador	13	1	0.84 6	inf	inf	Alta intermitencia (no predecible)
Bloque Auxiliar Frontal Para Guardamotor 3RV1901-1E	17	1	0.94 1	4	inf	Alta intermitencia (no predecible)
Bloque Terminal Rele	17	1	0.94 1	4	inf	Alta intermitencia (no predecible)
Brazo Engarsador con Perno 11307	31	5	0.64 5	10. 914	6.2 5	Alta intermitencia (no predecible)
Breaker Para Riel Dim (C60N/C10) 10AMP	31	1	0.90 3	15. 215	inf	Alta intermitencia (no predecible)
Buje Posterior Eje Principal 11441	31	2	0.90 3	5.0 04	25	Alta intermitencia (no predecible)
Buje Teflon 1"	17	1	0.94 1	4	inf	Alta intermitencia (no predecible)
Buje Teflon 2"	13	1	0.53 8	inf	inf	Alta intermitencia (no predecible)
Cadena Paso 100	36	2	0.83 3	8.4 03	5	Alta intermitencia (no predecible)
Cadena Paso 50	17	1	0.88 2	8.4 72	inf	Alta intermitencia (no predecible)
Cadena Paso 50-2	17	2	0.82 4	4.4 47	9	Alta intermitencia (no predecible)

Material	Meses	Meses con consumo	%C eros	CV	AD I	Clasificación
Cadena Paso 60	33	2	0.90 9	inf	14	Alta intermitencia (no predictible)
Cangilon 4"x 3"	24	3	0.79 2	4.2 69	11	Alta intermitencia (no predictible)
Cangilon 7"x 5"	46	1	0.93 5	16. 396	inf	Alta intermitencia (no predictible)
Cepillo Bancos 1000 mm	34	1	0.94 1	6.2 16	inf	Alta intermitencia (no predictible)
Cepillo Bancos 800 mm	35	1	0.88 6	8.2 44	inf	Alta intermitencia (no predictible)
Chumacera FY60TF YAR-212-2F	17	1	0.88 2	14. 832	inf	Alta intermitencia (no predictible)
Chumacera UCF206- 103D1	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Cinta Elevadores 4"x 4 lonas	55	2	0.92 7	inf	37	Alta intermitencia (no predictible)
Cinta Elevadores 8"x 4 lonas	13	1	0.84 6	inf	inf	Alta intermitencia (no predictible)
Conector Profibus GES7972-0BAS2-0XA0	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Contactador 3RT1023- 1AG24 (4KW) 100V	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Contactador 3RT1034- 1AN24 (15KW)	27	1	0.92 6	inf	inf	Alta intermitencia (no predictible)
Contactador 3RT1044- 1AN24 (30KW)	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Contactador LC1 DWK12M7	17	1	0.88 2	5.1 6	inf	Alta intermitencia (no predictible)

Material	Meses	Meses con consumo	%C eros	CV	AD I	Clasificación
Contactador LC1K0910MT	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Control de Temperatura DMS1141	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Control de Temperatura TAS-B4RJZC (0°-200°C)	36	2	0.83 3	27. 477	35	Alta intermitencia (no predictable)
Correa 420 SLV 5	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Correa 475 SLV 5	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Correa 500 SLV 5	24	1	0.83 3	21. 331	inf	Alta intermitencia (no predictable)
Correa 630x25 VCR 2107	28	1	0.82 1	22. 738	inf	Alta intermitencia (no predictable)
Correa 630x50 DVO 1152632	48	5	0.60 4	inf	6.7 5	Alta intermitencia (no predictable)
Correa A15445	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Correa A39	28	1	0.92 9	inf	inf	Alta intermitencia (no predictable)
Correa A96	54	2	0.92 6	18. 708	19	Alta intermitencia (no predictable)
Correa B174	40	2	0.87 5	9.6 6	26	Alta intermitencia (no predictable)
Correa B186	53	3	0.84 9	17. 149	21	Alta intermitencia (no predictable)
Correa B24505	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)

Material	Meses	Meses con consumo	%C eros	CV	AD I	Clasificación
Correa B36	38	2	0.86 8	7.9 54	23	Alta intermitencia (no predictible)
Correa B42	38	1	0.86 8	inf	inf	Alta intermitencia (no predictible)
Correa B44	53	1	0.96 2	9.9 55	inf	Alta intermitencia (no predictible)
Correa B55	34	1	0.91 2	19. 313	inf	Alta intermitencia (no predictible)
Correa B74	30	2	0.86 7	6.3 56	23	Alta intermitencia (no predictible)
Correa B80	36	2	0.88 9	9.5 39	23	Alta intermitencia (no predictible)
Correa B87	23	1	0.91 3	inf	inf	Alta intermitencia (no predictible)
Correa B88	24	2	0.87 5	5.9 16	23	Alta intermitencia (no predictible)
Correa B92	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Correa C62	36	1	0.94 4	21. 61	inf	Alta intermitencia (no predictible)
Correa CXA/STD 1552	30	1	0.9	18. 138	inf	Alta intermitencia (no predictible)
Correa Eslabon Tipo A	17	2	0.88 2	2.9 8	15	Alta intermitencia (no predictible)
Correa M38	56	1	0.91 1	65. 658	inf	Alta intermitencia (no predictible)
Correa M49	36	1	0.97 2	5.9 16	inf	Alta intermitencia (no predictible)

Material	Meses	Meses con consumo	%C eros	CV	AD I	Clasificación
Correa XL150	22	4	0.54 5	5.8 69	7	Alta intermitencia (no predictible)
Correa XL160	46	1	0.93 5	10. 404	inf	Alta intermitencia (no predictible)
Correa XL170	36	2	0.88 9	8.6 6	19	Alta intermitencia (no predictible)
Correa XPA2582	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Cuchilla Fija 11703	33	4	0.78 8	6.3 18	10. 667	Alta intermitencia (no predictible)
Cuchilla Movil 11702	35	5	0.71 4	8.2 22	8.5	Alta intermitencia (no predictible)
Desentrapador de Clasificación MPAA- 40066-01	17	1	0.88 2	4.0 65	inf	Alta intermitencia (no predictible)
Desentrapador de Harina MPAA-40068-01	33	1	0.78 8	6.4 01	inf	Alta intermitencia (no predictible)
Diente de Arrastre 11203	35	2	0.91 4	5.8 31	34	Alta intermitencia (no predictible)
Display de Variador de Frecuencia VW3A1101	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Eje Principal 11600	13	1	0.84 6	inf	inf	Alta intermitencia (no predictible)
Electrovalvula C66239	31	2	0.87 1	inf	26	Alta intermitencia (no predictible)
Estación de Mando 26662	37	1	0.94 6	inf	inf	Alta intermitencia (no predictible)
Excentrica de Looper Ref 40310	30	2	0.86 7	8.6 02	15	Alta intermitencia (no predictible)

Material	Meses	Meses con consumo	%C eros	CV	AD I	Clasificación
Grasa Alta Temperatura x 35 Lbs	25	2	0.4	inf	20	Alta intermitencia (no predictable)
Grasa Alta Temperatura x Cuñete 35 Lbs	38	3	0.05 3	inf	17	Alta intermitencia (no predictable)
Grasa BEG	22	1	0.63 6	inf	inf	Alta intermitencia (no predictable)
Grasa Chasis x Cuñete 35 Lbs	38	3	0.44 7	inf	6	Alta intermitencia (no predictable)
Guardamotor 3RV1011-1HA10 (5.5-8A)	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Guardamotor 3RV1031-4FA10 (28-40A)	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Guardamotor 3RV1041-4JA10 (45-63A)	17	1	0.88 2	9.1 65	inf	Alta intermitencia (no predictable)
Guardamotor 3RV1041-4KA10 (57-75A)	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Guardamotor 3RV1041-4MA10 (80-100A)	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Guardamotor 3RV2011-1JA10 (7-10A) 2HP	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Juego de Martillos x 24 un	49	5	0.81 6	20. 976	12	Alta intermitencia (no predictable)
Kit GA11	31	2	0.87 1	inf	29	Alta intermitencia (no predictable)
Looper 11300	33	1	0.93 9	7.2 54	inf	Alta intermitencia (no predictable)
Manga Colectora NT CAL 350 (245x18cm)	40	2	0.9	16. 703	37	Alta intermitencia (no predictable)

Material	Meses	Meses con consumo	%C eros	CV	AD I	Clasificación
Manga Nylon AT (30x19)	23	1	0.78 3	5.5 83	inf	Alta intermitencia (no predictible)
Mango Rodamiento AHX2315	18	2	0.88 9	2.8 28	17	Alta intermitencia (no predictible)
Mango Rodamiento H2308	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Mango Rodamiento H2313	18	2	0.88 9	2.8 28	8	Alta intermitencia (no predictible)
Mango Rodamiento H315	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Mango rodamiento HE210X	12	1	0.91 7	3.3 17	inf	Alta intermitencia (no predictible)
Medidor de Presión PI008A	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Motobomba Monofasica 1841	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Palanca eleva barra de aguja 11025	18	2	0.77 8	7.2 8	13	Alta intermitencia (no predictible)
Paro de Emergencia XB4B58442	37	1	0.94 6	13. 565	inf	Alta intermitencia (no predictible)
Pasta para Bandas	52	1	0.94 2	9.7 29	inf	Alta intermitencia (no predictible)
Pegamento Instantaneo 50 g	20	2	0.7	inf	14	Alta intermitencia (no predictible)
Pegamento Ultrafix 450 g	43	4	0.23 3	inf	12. 667	Alta intermitencia (no predictible)
Pie de Arrastre 11400	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)

Material	Meses	Meses con consumo	%C eros	CV	AD I	Clasificación
Piloto Led Naranja 22 mm	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Piloto Led Rojo 22 mm	32	2	0.81 2	12. 765	24	Alta intermitencia (no predictable)
Piloto Led Verde 22 mm	17	1	0.88 2	4.5 59	inf	Alta intermitencia (no predictable)
Piloto verde XB4 BVM3	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Plancha 11210	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Polea Maquina 11904	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Polea Motor 11902	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Protector de Banda 11101	28	1	0.89 3	17. 521	inf	Alta intermitencia (no predictable)
Pulsador 900 1KR18H13 Negro	25	2	0.88	7.2 2	24	Alta intermitencia (no predictable)
Pulsador 900 1KR1GH13 Verde	22	1	0.86 4	inf	inf	Alta intermitencia (no predictable)
Pulsador 900 1KR1RH13 Rojo	25	2	0.92	4	24	Alta intermitencia (no predictable)
Pulsador Completo con Piloto XB4BW73731G5	17	1	0.88 2	7.3 33	inf	Alta intermitencia (no predictable)
Rele Finder 24V-24V	17	1	0.88 2	4.7 55	inf	Alta intermitencia (no predictable)
Rele Finder 24V-250V	17	2	0.76 5	5.1 88	9	Alta intermitencia (no predictable)

Material	Meses	Meses con consumo	%C eros	CV	AD I	Clasificación
Rele Tiempo 3RP1513-1AP30 (5-100seg)	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Rele Tiempo 3RP1574-1NP30 (1-20seg)	17	1	0.88 2	9.1 65	inf	Alta intermitencia (no predictable)
Rele Tiempo 3RP1574-1NQ30 (1-20seg)	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Rele Térmico LR2 K0314 (5.5-8A)	31	1	0.93 5	inf	inf	Alta intermitencia (no predictable)
Rele Térmico LRD22 (16-24A)	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Rele de Estado Solido TD48A40 (4-32VDC)	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Relevo R4N-2014-231024WTL (24V)	27	2	0.81 5	inf	9	Alta intermitencia (no predictable)
Relevo R4N-2014-235230WTL (230V)	17	2	0.82 4	3.7 08	9	Alta intermitencia (no predictable)
Resistencia 230V-250W	35	2	0.8	17. 219	20	Alta intermitencia (no predictable)
Reten 100-120-10	18	2	0.72 2	5.5 73	17	Alta intermitencia (no predictable)
Reten 130-160-15	32	1	0.93 8	12. 61	inf	Alta intermitencia (no predictable)
Reten 22-38-8	18	2	0.83 3	4.1 23	17	Alta intermitencia (no predictable)
Reten 30-52-10	17	1	0.88 2	4.4 94	inf	Alta intermitencia (no predictable)
Reten 30-52-8	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)

Material	Meses	Meses con consumo	%C eros	CV	AD I	Clasificación
Reten 30-57-10	17	1	0.88 2	4.4 94	inf	Alta intermitencia (no predictible)
Reten 35-57-9	27	2	0.81 5	7.1 65	17	Alta intermitencia (no predictible)
Reten 35-62-7	32	1	0.96 9	5.5 68	inf	Alta intermitencia (no predictible)
Reten 40-47-4	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Reten 42-72-10	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Reten 50-90-10	38	1	0.92 1	inf	inf	Alta intermitencia (no predictible)
Reten 60-82-10	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Reten 60-90-10	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Reten 65-85-10	18	3	0.72 2	4.6 97	8.5	Alta intermitencia (no predictible)
Reten 70-90-10	18	2	0.66 7	6.3 74	17	Alta intermitencia (no predictible)
Reten 85-105-10	17	1	0.82 4	6.6 11	inf	Alta intermitencia (no predictible)
Reten 90-110-10	18	2	0.88 9	2.8 91	17	Alta intermitencia (no predictible)
Reten TSN516L	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Rodamiento 1210K/C3	12	1	0.91 7	3.3 17	inf	Alta intermitencia (no predictible)

Material	Meses	Meses con consumo	%C eros	CV	AD I	Clasificación
Rodamiento 22216 EK	22	2	0.86 4	8.0 62	17	Alta intermitencia (no predictible)
Rodamiento 22308	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Rodamiento 22313 EK	17	2	0.88 2	2.9 06	9	Alta intermitencia (no predictible)
Rodamiento 22315 EK	19	2	0.78 9	15. 684	4	Alta intermitencia (no predictible)
Rodamiento 23224- CC/C3W33	32	1	0.96 9	5.5 68	inf	Alta intermitencia (no predictible)
Rodamiento 6000	21	3	0.76 2	6.4 03	8.5	Alta intermitencia (no predictible)
Rodamiento 6003	43	3	0.83 7	16. 031	19	Alta intermitencia (no predictible)
Rodamiento 6004	32	2	0.75	8.9 8	22	Alta intermitencia (no predictible)
Rodamiento 6006	12	1	0.91 7	3.3 17	inf	Alta intermitencia (no predictible)
Rodamiento 6007	37	2	0.91 9	6	36	Alta intermitencia (no predictible)
Rodamiento 6010	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Rodamiento 6203	32	2	0.81 2	inf	22	Alta intermitencia (no predictible)
Rodamiento 6204	35	2	0.82 9	11. 111	17	Alta intermitencia (no predictible)
Rodamiento 6205	20	1	0.9	5.3 48	inf	Alta intermitencia (no predictible)

Material	Meses	Meses con consumo	%C eros	CV	AD I	Clasificación
Rodamiento 6206	36	3	0.778	inf	13	Alta intermitencia (no predictable)
Rodamiento 6207	20	3	0.8	3.102	9.5	Alta intermitencia (no predictable)
Rodamiento 6208	17	1	0.882	5.338	inf	Alta intermitencia (no predictable)
Rodamiento 6209	36	1	0.917	inf	inf	Alta intermitencia (no predictable)
Rodamiento 6210	17	1	0.941	4	inf	Alta intermitencia (no predictable)
Rodamiento 6212	17	2	0.882	2.906	9	Alta intermitencia (no predictable)
Rodamiento 6302	23	2	0.87	3.754	22	Alta intermitencia (no predictable)
Rodamiento 6307	47	1	0.936	31.401	inf	Alta intermitencia (no predictable)
Rodamiento 6308	22	2	0.909	3.162	19	Alta intermitencia (no predictable)
Rodamiento 6309	20	2	0.9	3	19	Alta intermitencia (no predictable)
Rodamiento 6316 M/C3VL0241	17	1	0.941	4	inf	Alta intermitencia (no predictable)
Rodamiento 6902 DD	36	2	0.917	7.28	35	Alta intermitencia (no predictable)
Rodamiento 7206 B	17	1	0.941	4	inf	Alta intermitencia (no predictable)
Rodamiento KR40	38	2	0.868	24.249	33	Alta intermitencia (no predictable)

Material	Meses	Meses con consumo	%C eros	CV	AD I	Clasificación
Rodamiento NK30/20	18	2	0.88 9	2.8 28	17	Alta intermitencia (no predictible)
Rodamiento NU312	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Rodamiento NU313	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Rodamiento UC205	21	2	0.90 5	3.4 82	4	Alta intermitencia (no predictible)
Rodamiento UC207	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Rodamiento UC212	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Rodamiento UEL209	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Rueda Estibador 117	12	1	0.83 3	inf	inf	Alta intermitencia (no predictible)
Sensor de Proximidad CR18-8A0	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Sensor de Proximidad Capacitivo KI505A	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Soporte Cono 11720	38	2	0.89 5	16. 279	1	Alta intermitencia (no predictible)
Soporte Cuchilla 11007	17	2	0.82 4	7.0 71	1	Alta intermitencia (no predictible)
Soporte Lopper 11301	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Soporte Motor	21	2	0.81	10. 7	1	Alta intermitencia (no predictible)

Material	Meses	Meses con consumo	%C eros	CV	AD I	Clasificación
Switch Motor 11819	35	3	0.82 9	5.8 31	17	Alta intermitencia (no predictible)
Switch Muletilla XB4BD21	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Tela Cernido 10XXX (132 mc)	52	7	0.42 3	11. 813	7.8 33	Moderada (predictible con limitaciones)
Tela Cernido 11XXX (118 mc)	48	5	0.62 5	6.5 95	11. 75	Alta intermitencia (no predictible)
Tela Cernido 12XXX (112 mc)	48	5	0.85 4	4.0 9	11. 75	Alta intermitencia (no predictible)
Tela Cernido 6XXX (212 mc)	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Tela Cernido 8XXX (180 mc)	17	1	0.94 1	4	inf	Alta intermitencia (no predictible)
Tela Cernido 9XXX (150 mc)	35	5	0.65 7	3.2 07	8.5	Alta intermitencia (no predictible)
Tela Clasificación 36GG (530 mc)	32	3	0.81 2	4.9 22	2	Alta intermitencia (no predictible)
Tela Clasificación 40GG (475 mc)	18	2	0.88 9	2.9 12	1	Alta intermitencia (no predictible)
Tela Clasificación 42GG (450 mc)	18	3	0.83 3	2.7 69	2	Alta intermitencia (no predictible)
Tela Clasificación 44GG (425 mc)	18	2	0.83 3	2.8 95	1	Alta intermitencia (no predictible)
Tela Clasificación 47GG (375 mc)	18	3	0.83 3	2.5 98	2	Alta intermitencia (no predictible)
Tela Clasificación 52GG (335 mc)	18	2	0.83 3	2.9 03	1	Alta intermitencia (no predictible)

Material	Meses	Meses con consumo	%C eros	CV	AD I	Clasificación
Tela Clasificación 54GG (315 mc)	18	2	0.88 9	3.1 27	1	Alta intermitencia (no predictable)
Tela Clasificación 60GG (280 mc)	44	3	0.84 1	6.9 53	7	Alta intermitencia (no predictable)
Tela Clasificación 66GG (250 mc)	42	4	0.85 7	4.1 04	5	Alta intermitencia (no predictable)
Tela Clasificación 74GG (212 mc)	29	2	0.89 7	3.7 14	11	Alta intermitencia (no predictable)
Tela Metalica STS 17 1250/72	18	1	0.94 4	4.1 23	inf	Alta intermitencia (no predictable)
Tela Metalica STS 19 1120/70	18	1	0.83 3	7.2 8	inf	Alta intermitencia (no predictable)
Tela Metalica STS 21 1000/67	18	1	0.94 4	4.1 23	inf	Alta intermitencia (no predictable)
Tela Sasor 20GG (1000 mc)	17	2	0.76 5	4.6 3	13	Alta intermitencia (no predictable)
Tela Sasor 22GG (950 mc)	17	1	0.88 2	4.0 77	inf	Alta intermitencia (no predictable)
Tela Sasor 30GG (670 mc)	17	1	0.88 2	4.2 29	inf	Alta intermitencia (no predictable)
Tela Sasor 32GG (600 mc)	17	3	0.76 5	4.2 06	4	Alta intermitencia (no predictable)
Tela Sasor 34GG (560 mc)	17	1	0.88 2	4.6 94	inf	Alta intermitencia (no predictable)
Temporizador TH3A-YA (6 minutos)	21	1	0.90 5	10. 198	inf	Alta intermitencia (no predictable)
Termocupla	35	2	0.82 9	16. 171	20	Alta intermitencia (no predictable)

Material	Meses	Meses con consumo	%C eros	CV	AD I	Clasificación
Tornillo cangilón 1/4 x 1.1/4	16	1	0.75	inf	inf	Alta intermitencia (no predictable)
Totalizador 3VM 1010-2ED32-0AA0 (100A)	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Totalizador Trifasico EZC100N (15A)	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Variador de frecuencia SINAMICS V20 (220V-1HP)	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)
Ventilador 200 x 200 x 60 mm 220V	17	1	0.88 2	4.9 15	inf	Alta intermitencia (no predictable)
Ventilador VN-583B (120V)	17	1	0.94 1	4	inf	Alta intermitencia (no predictable)

Del total de materiales evaluados:

234 materiales ($\approx 98.7\%$) fueron clasificados como de alta intermitencia y no predictibles bajo las condiciones actuales.

3 materiales ($\approx 1.3\%$) fueron clasificados como de intermitencia moderada, potencialmente predictibles con limitaciones.

Ningún material cumplió completamente los criterios de “predictible con suficiente historial”.

Estos resultados evidencian que la gran mayoría del inventario presenta una estructura altamente esporádica, con baja frecuencia de consumo y largos intervalos entre eventos positivos.

Este resultado explica de manera consistente:

- La presencia de valores negativos de R^2 en varios modelos.
- La dificultad de los modelos deep learning para generalizar.
- La mayor estabilidad relativa de Prophet frente a series con alta proporción de ceros.

Desde el punto de vista metodológico, se confirma que el principal desafío no radica en la elección del modelo, sino en la naturaleza estadística de la demanda. Cuando la densidad informativa es insuficiente, incluso arquitecturas avanzadas presentan limitaciones estructurales.

Este hallazgo refuerza la necesidad de realizar una clasificación previa antes de aplicar técnicas de predicción, evitando el uso indiscriminado de modelos en materiales sin condiciones mínimas de entrenamiento.

Conclusiones

La presente investigación permitió evaluar comparativamente distintos modelos predictivos aplicados a la demanda de repuestos en un entorno de mantenimiento industrial caracterizado por alta intermitencia. A partir del análisis de 36 materiales y del cálculo de métricas como MAE, RMSE y R^2 , se evidenció que el desempeño de los modelos depende directamente de la estructura estadística de la serie temporal.

El análisis del consumo histórico mensual confirmó que la mayoría de los materiales presentan un comportamiento altamente intermitente, con largos periodos sin consumo y picos esporádicos. Mediante indicadores como el porcentaje de meses sin consumo, el coeficiente de variación (CV^2) y el Average Demand Interval (ADI), fue posible clasificar los materiales según su nivel de irregularidad. Esta etapa resultó fundamental para interpretar adecuadamente los resultados del modelamiento.

En términos comparativos, el modelo Prophet mostró mayor estabilidad global frente a series con alta variabilidad y presencia frecuente de valores cero, obteniendo los menores errores promedio y el único R^2 promedio positivo. Por su parte, el modelo CNN + GRU + BiLSTM + Atención alcanzó desempeños superiores en aquellos materiales con patrones temporales más definidos, evidenciando que las arquitecturas profundas pueden capturar relaciones complejas cuando existe estructura suficiente en los datos.

Los resultados confirman que no existe un modelo universalmente óptimo para todos los materiales. La efectividad predictiva está condicionada por el nivel de intermitencia y la densidad informativa de la serie. En materiales extremadamente esporádicos, incluso modelos avanzados presentan limitaciones debido a la escasez de información estructurada.

El principal aporte del estudio radica en demostrar que la aplicación de modelos predictivos en inventarios de mantenimiento debe estar precedida por una caracterización estadística rigurosa de la demanda. La selección metodológica no puede realizarse de manera generalizada, sino que debe basarse en criterios objetivos que identifiquen cuándo la predicción es viable y cuándo los datos no permiten un ajuste confiable.

En consecuencia, la investigación aporta un marco comparativo que contribuye a la comprensión de la pertinencia de distintos enfoques predictivos en escenarios de demanda intermitente, fortaleciendo el análisis metodológico dentro del campo de la ciencia de datos aplicada al mantenimiento industrial.

Recomendaciones

A partir de los resultados obtenidos en el análisis comparativo, se recomienda que la aplicación de modelos predictivos en inventarios de repuestos no se realice de manera generalizada, sino que esté precedida por una clasificación estadística rigurosa de la demanda. La selección del modelo debe basarse en el nivel de intermitencia y variabilidad de cada material. En este sentido, los resultados sugieren que modelos como Prophet presentan mayor estabilidad en materiales con alta irregularidad, mientras que arquitecturas profundas como CNN + GRU + BiLSTM + Atención muestran mejor desempeño cuando la serie presenta patrones temporales más definidos. Adoptar un esquema de selección diferencial permitiría mejorar la pertinencia metodológica del modelamiento.

Se recomienda incorporar de manera sistemática el cálculo de métricas como el porcentaje de períodos sin consumo, el Average Demand Interval (ADI) y el coeficiente de variación (CV^2) como paso previo obligatorio antes de entrenar cualquier modelo. Esta caracterización permite identificar si la serie cuenta con condiciones mínimas para un entrenamiento confiable. En materiales con intermitencia extrema, puede resultar más adecuado utilizar reglas simples de reposición en lugar de aplicar modelos complejos que no cuentan con suficiente información estructurada.

Asimismo, se sugiere complementar los esquemas tradicionales de clasificación ABC/XYZ con criterios derivados del análisis predictivo. Integrar variables como nivel de intermitencia, estabilidad del modelo y comportamiento proyectado permitiría una priorización más objetiva de los materiales. De esta manera, la gestión del inventario podría diferenciar entre repuestos con comportamiento predecible y aquellos cuya demanda no es metodológicamente modelable bajo las condiciones actuales.

En caso de que la organización decida implementar los modelos en un entorno operativo, se recomienda realizar una integración progresiva dentro del ERP SAP Business One, mediante paneles analíticos que permitan visualizar tendencias históricas, proyecciones de consumo y estimaciones de reposición. Esta integración debe acompañarse de un proceso continuo de validación del desempeño de los modelos, con el fin de ajustar parámetros y verificar su estabilidad en el tiempo.

Adicionalmente, se recomienda explorar la incorporación de variables operativas complementarias, tales como criticidad del activo, frecuencia de fallas, horas de operación o mantenimientos programados. La inclusión de estos factores permitiría evolucionar hacia modelos multivariados con mayor capacidad explicativa, superando las limitaciones propias del análisis basado exclusivamente en consumo histórico.

Finalmente, se sugiere documentar y conservar de manera estructurada el código, las bases de datos depuradas, los modelos entrenados y los resultados obtenidos, garantizando reproducibilidad metodológica y continuidad técnica. La consolidación de un repositorio analítico institucional facilitaría futuras actualizaciones, ajustes o ampliaciones del estudio, así como su posible aplicación en otras áreas del mantenimiento industrial.

Referencias

Advanced Factories. (2024). *Mantenimiento predictivo potenciado por IA: el futuro de la gestión industrial*. <https://www.advancedfactories.com>

Artero Consultores. (2023). *SAP Business One mantenimiento preventivo*.
<https://arteroconsultores.com>

BII World. (2025). *Data science & AI for maintenance professionals*. <https://biiworld.com>

Dilarce. (2024). *Gestión de repuestos industriales con RFID y QR*. <https://dilarce.com>

EasyMaint. (2024). *Inventarios de repuestos de mantenimiento: clave para la eficiencia*.
<https://www.easy-maint.net>

EVSA Group. (2025). *Tendencias en mantenimiento industrial y de instalaciones 2025*.
<https://evsagroup.com>

Fractal. (2024). *El papel de los gemelos digitales en el mantenimiento industrial*.
<https://www.fractal.com/es>

Fractal. (2025). *Futuro del mantenimiento industrial: tendencias 2025*.
<https://www.fractal.com/es>

Infraspeak. (2025). *Mantenimiento: estadísticas, tendencias y desafíos*.
<https://blog.infraspeak.com>

Mint Logística. (2023). *Clasificación ABC y XYZ en la gestión de inventarios industriales*.
<https://mintlogistica.com>

ML Journey. (2025). *Forecasting intermittent demand with machine learning*.
<https://mljourney.com>

SAP. (2025). *SAP Business One overview*. <https://www.sap.com/products/business-one.html>

Suministros Herco. (2025). *Cómo aplicar mantenimiento predictivo con inteligencia artificial.*

<https://www.suministrosherco.com>

Syntetos, A. A., & Boylan, J. E. (2023). *Intermittent demand forecasting: Recent developments*

and future directions. <https://www.sciencedirect.com>

TÜV SÜD. (2023). *Optimización del inventario de repuestos en mantenimiento industrial.*

<https://www.tuvsud.com/es-es>

VisualK Group. (2021). *Soluciones de mantenimiento para SAP Business One.*

<https://visualkgroup.com>

VisualK Group. (2024). *Mantenimiento industrial integrado con SAP Business One.*

<https://visualkgroup.com>

Zucchetti. (2025). *Cómo la ciencia de datos transforma el mantenimiento predictivo.*

<https://zucchetti.es>