

Implementación de una Herramienta de Pronóstico de Demanda de Energía Eléctrica en
Santander Utilizando el Método de Random Forest y Basada en PyCaret

Edwin Armando Ariza Peñaloza

Trabajo de Grado para Optar al Título de Ingeniero Electricista

Director

Ivan David Serna Suarez

Ph.D Ingeniería Eléctrica

Universidad Industrial de Santander

Facultad de Ingenierías Fisicomecánicas

Escuela de Ingeniería Eléctrica, Electrónica y de Telecomunicaciones

Ingeniería eléctrica.

Bucaramanga

2024

Dedicatoria

A mi señor padre Heriberto Ariza Arce a quien en vida le llenaba de orgullo saber que tenía un hijo estudiando en la universidad de más prestigio en el departamento.

Agradecimientos

A la Universidad Industrial de Santander y al cuerpo docente de la Escuela de Ingeniería Eléctrica y Electrónica por todos los conocimientos aportados y las metodologías de enseñanza aplicadas a lo largo de este proceso de construcción profesional.

A todos aquellos familiares y amigos que siempre tuvieron una voz de aliento para fortalecer la motivación en el esfuerzo por caminar día a día en este proyecto que requirió nuevas formas de repensar el trabajo como ingeniero eléctrico.

Tabla de Contenido

	Pág.
Introducción	13
1. Descripción del Problema	15
2. Objetivos	18
2.1 Objetivo General	18
2.2 Objetivos Específicos	18
3. Fundamentación Teórica.....	19
3.1 Estado del Arte	19
3.1.1 Métodos Tradicionales de Pronósticos.....	19
3.1.2 Aplicaciones Clave De Los Métodos De Pronóstico Basados En IA.....	20
3.2 Marco Teórico.....	23
3.2.1 Concepto de Inteligencia Artificial	23
3.2.2 Redes Neuronales y Machine Learning	23
3.2.5 Herramientas Informáticas en Aplicaciones de IA	26
3.2.6 PyCaret.....	28
3.2.7 Random Forest	29
3.2.8 LSTM (Long Short-Term Memory).....	31
4. Metodología	34
4.1 Método	34
4.2 Código de PyCaret utilizado en el proyecto.....	42
5. Resultados	44
5.1 Recolección de Datos Históricos y Estadísticas Descriptivas.....	44

5.1 Recolección de Datos Históricos.....	44
5.2 Estadísticas Descriptivas	45
5.2 Aplicación y Evaluación de Desempeño de Técnicas para Estimación y Pronóstico de Demanda	48
5.2.1.3 Descripción del Modelo LSTM Elegido Como Mejor Ajuste y Random Forest Como Métodos Para Pronosticar la Demanda de Energía Eléctrica en Santander	49
5.2.2 Implementación de Técnicas Seleccionadas como Favorables para el Pronóstico	53
5.2.2.1 Pronóstico Bajo las Estrategias de Rolling Horizon Convencional y por Segmentación por Días, para Pronosticar la Demanda de la Primera Semana de Enero 2024.....	54
5.2.2.2 Evaluación del Desempeño de las Estrategias Rolling Horizon Analizadas para Pronosticar la Primera Semana de 2024.....	56
5.2.2.3 Análisis de los Pronósticos para Ventanas Temporales Anual, Mensual, y Semanal.....	61
6. Conclusiones	67
6.1 Elección de la técnica LSTM como mejor ajuste.....	67
6.2 Implementación y Evaluación de los Modelos Para Realizar Pronósticos.....	67
6.3 Evaluación del Desempeño de los Modelos.....	69
7. Recomendaciones	71
Referencias Bibliográficas.....	72

Lista de Tablas

	Pág.
Tabla 1. <i>Relación de Estudios Representativos en Santander de Métodos de Pronóstico de Demanda de Energía</i>	16
Tabla 2. <i>Código general de PyCaret utilizado en el proyecto y comandos específicos para los métodos Random Forest y LSTM</i>	42
Tabla 8. <i>Comparación de Indicadores de Desempeño de los Modelos</i>	37
Tabla 3. <i>Medidas de desempeño del modelo Random Forest</i>	50
Tabla 6. <i>Medidas de desempeño del modelo LSTM</i>	51
Tabla 9. <i>Resumen de valores de demanda real y demanda pronosticada según el CND y los cuatro pronósticos generados en el proyecto para la primera semana del 2024</i>	56
Tabla 10. <i>Comparación de Indicadores de Rendimiento entre Modelos para Predicción Primera Semana de 2024</i>	57
Tabla 11. <i>Resumen del indicador MAPE para el pronóstico de los primeros 5 días de la primera semana del 2024 y de dicha semana completa (7 días)</i>	59
Tabla 12. <i>MAPE obtenido al pronosticar un año de demanda con los modelos Random Forest y LSTM entre 2019 y 2024</i>	62
Tabla 13. <i>MAPE obtenido al pronosticar un mes de demanda (enero específicamente) con los modelos Random Forest y LSTM en los años 2018 y 2023</i>	64
Tabla 14. <i>MAPE obtenido al pronosticar la primera semana de enero con los modelos Random Forest y LSTM en los años 2019 y 2024</i>	64

Lista de Figuras

	Pág.
Figura 1. <i>Modelado de Sistemas de Pronóstico de Mercado Basado en IA</i>	21
Figura 2. <i>Pantallazo de Estadísticas Descriptivas Básicas de los datos a analizar</i>	45
Figura 3. <i>Histograma de Frecuencias de los datos</i>	46
Figura 4. <i>Diagrama de Dispersión de los datos</i>	47
Figura 10. <i>Comparativa gráfica de los indicadores de rendimiento de los diferentes modelos</i> ...	37
Figura 5. <i>Ajuste con Random Forest</i>	49
Figura 8. <i>Ajuste del Modelo LSTM</i>	51
Figura 11. <i>Comparativa gráfica del pronóstico obtenido con la estrategia rolling horizon con segmentación por días</i>	54
Figura 12. <i>Comparativa gráfica del pronóstico obtenido con la estrategia rolling horizon convencional</i>	55
Figura 13. <i>Comparativa gráfica de los indicadores de rendimiento de los diferentes modelos Predicción Primera Semana 2024</i>	58
Figura 14. <i>Comparativa gráfica del MAPE para los pronósticos de los primeros 5 días y los 7 días completos de la primera semana del 2024</i>	59
Figura 25. <i>Comparativo de datos reales versus pronosticados de lo corrido del año 2024 – Enero a Agosto (Random Forest)</i>	61
Figura 26. <i>Comparativo de datos reales versus pronosticados de lo corrido del año 2024 – Enero a Agosto (LSTM)</i>	63

Figura 26. <i>Comparativo del MAPE obtenido para ventas temporales anual, mensual, semanal con Random Forest</i>	65
Figura 26. <i>Comparativo del MAPE obtenido para ventas temporales anual, mensual, semanal con LSTM</i>	66
Figura 15. <i>Comparativo de datos reales versus pronosticados para el año 2019 (Random Forest)</i>	78
Figura 16. <i>Comparativo de datos reales versus pronosticados para el año 2019 (LSTM)</i>	78
Figura 17. <i>Comparativo de datos reales versus pronosticados para el año 2020 (Random Forest)</i>	79
Figura 18. <i>Comparativo de datos reales versus pronosticados para el año 2020 (LSTM)</i>	80
Figura 19. <i>Comparativo de datos reales versus pronosticados para el año 2021 (Random Forest)</i>	80
Figura 20. <i>Comparativo de datos reales versus pronosticados para el año 2021 (LSTM)</i>	81
Figura 21. <i>Comparativo de datos reales versus pronosticados para el año 2022 (Random Forest)</i>	81
Figura 22. <i>Comparativo de datos reales versus pronosticados para el año 2022 (LSTM)</i>	82
Figura 23. <i>Comparativo de datos reales versus pronosticados para el año 2023 (Random Forest)</i>	82
Figura 24. <i>Comparativo de datos reales versus pronosticados para el año 2023 (LSTM)</i>	83

Glosario

Algoritmo: Conjunto de instrucciones definidas y ordenadas que permiten realizar una tarea o resolver un problema.

ANN (Redes Neuronales Artificiales): Modelo computacional inspirado en la estructura del cerebro humano, utilizado para reconocer patrones y hacer predicciones basadas en datos.

API: Interfaz de programación de aplicaciones, un conjunto de definiciones y protocolos que permite que dos aplicaciones se comuniquen entre sí.

Dataset (Conjunto de Datos): Colección de datos que se utiliza para entrenar y evaluar modelos de machine learning.

División de Datos: Proceso de separar un conjunto de datos en subconjuntos, típicamente en datos de entrenamiento y datos de prueba.

Entrenamiento de Modelo: Proceso de ajustar un modelo de machine learning a los datos de entrenamiento, permitiéndole aprender a hacer predicciones.

Error Absoluto Medio (MAE): Métrica que calcula el promedio de los errores absolutos entre las predicciones y los valores reales.

Error Cuadrático Medio (MSE): Métrica que calcula el promedio de los errores al cuadrado entre las predicciones y los valores reales, dando más peso a los errores grandes.

Evaluación de Modelo: Proceso de medir el desempeño de un modelo de machine learning utilizando métricas específicas.

Feature (Característica): Una variable individual en un conjunto de datos utilizada como entrada para un modelo de machine learning.

Hiperparámetros: Parámetros cuyo valor se fija antes del proceso de entrenamiento de un modelo de machine learning y que controlan su comportamiento.

Inteligencia Artificial (IA): Es el campo de la informática que se ocupa de desarrollar sistemas y algoritmos capaces de realizar tareas que requieren inteligencia humana, como el aprendizaje automático, el razonamiento, la toma de decisiones y el procesamiento del lenguaje natural.

MAE (Mean Absolute Error): Ver **Error Absoluto Medio**.

MSE (Mean Squared Error): Ver **Error Cuadrático Medio**.

PyCaret: Biblioteca de Python de código abierto que simplifica el flujo de trabajo de machine learning, proporcionando herramientas para preprocesamiento de datos, entrenamiento de modelos y evaluación.

Random Forest: Algoritmo de aprendizaje automático de ensemble que construye múltiples árboles de decisión y los combina para mejorar la precisión y reducir el sobreajuste.

R² (Coeficiente de Determinación): Métrica que indica qué tan bien los datos predichos se ajustan a los datos observados, donde 1 indica un ajuste perfecto.

SVM (Máquinas de Vectores de Soporte): Algoritmo de aprendizaje supervisado que se utiliza para la clasificación y regresión, encontrando el hiperplano óptimo que separa los datos en diferentes clases.

Sobreajuste (Overfitting): Situación en la que un modelo de machine learning se ajusta demasiado a los datos de entrenamiento, capturando el ruido y las anomalías, lo que resulta en un mal desempeño en datos nuevos.

Validación de Modelo: Proceso de probar un modelo de machine learning en un conjunto de datos independiente para evaluar su capacidad de generalización.

Visualización de Datos: Representación gráfica de datos e información para facilitar su comprensión y análisis.

Resumen

Título: Implementación de una Herramienta de Pronóstico de Demanda de Energía Eléctrica en Santander Utilizando el Método de Random Forest y Basada en PyCaret *

Autor: Edwin Armando Ariza Peñaloza **

Palabras Clave: Predicción de Demanda Energética, Machine Learning, Random Forest

Descripción: El pronóstico preciso de la demanda de energía eléctrica es esencial para la gestión eficiente de los recursos energéticos, especialmente en regiones con características particulares como Santander. Sin embargo, el sector energético en esta región enfrenta desafíos significativos debido a la variabilidad en la demanda y a las limitaciones de los modelos predictivos existentes. El propósito principal de este estudio es desarrollar y validar modelos predictivos avanzados para estimar la demanda de energía eléctrica en Santander, con el objetivo de superar las deficiencias de los enfoques tradicionales. Se emplean dos modelos de vanguardia: Random Forest y Long Short-Term Memory (LSTM), que son comparados en términos de su precisión y utilidad práctica. El análisis se basa en datos históricos y utiliza herramientas de datos como PyCaret y Google Colab. Los resultados obtenidos muestran que el modelo Random Forest ofrece una mejora significativa en la precisión de los pronósticos en comparación con el modelo LSTM, destacando su capacidad para capturar patrones complejos y dinámicos en los datos de demanda de energía eléctrica en Santander. Los hallazgos subrayan la importancia de adoptar enfoques modernos en la predicción de la demanda para mejorar la gestión energética en contextos regionales específicos.

* Trabajo de Pregrado

** Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería Eléctrica, Electrónica y de Telecomunicaciones. Ingeniería eléctrica. Director: Ivan David Serna Suarez. Ph. D.

Abstract

Title: Implementation of an Electric Energy Demand Forecasting Tool in Santander Using the Random Forest Method and Based on PyCaret *

Author(s): Edwin Armando Ariza Peñaloza **

Key Words: Energy Demand Prediction, Machine Learning, Random Forest

Description: Accurate forecasting of electric power demand is essential for efficient management of energy resources, especially in regions with characteristics such as Santander. However, the energy sector in this region faces significant challenges due to variability in demand and limitations of existing predictive models. The main purpose of this study is to develop and validate advanced predictive models to estimate electric power demand in Santander, with the aim of overcoming the shortcomings of traditional approaches. Two state-of-the-art models are employed: Random Forest and Long Short-Term Memory (LSTM), which are compared in terms of their accuracy and practical utility. The analysis is based on historical data and uses data tools such as PyCaret and Google Colab. The results obtained show that the Random Forest model offers a significant improvement in forecasting accuracy compared to the LSTM model, highlighting its ability to capture complex and dynamic patterns in electricity demand data in Santander. The findings underline the importance of adopting modern approaches in demand forecasting to improve energy management in specific regional contexts.

* Pregraduate Degree Work

** Faculty of Physical and Mechanical Engineering. School of Electrical, Electronic and Telecommunications Engineering. Electrical engineering. Director: Ivan David Serna Suarez. Ph. D.

Introducción

En la actualidad, la gestión eficiente de la demanda de energía eléctrica es crucial para el desarrollo sostenible de las sociedades modernas. Con el incremento de la población y la expansión de las actividades industriales y comerciales, las redes eléctricas enfrentan desafíos significativos en términos de estabilidad y capacidad de respuesta. La previsión precisa de la demanda energética se convierte en una herramienta esencial para optimizar la producción y distribución de electricidad, así como para garantizar la estabilidad del suministro y la eficiencia en el uso de recursos.

El problema general que enfrenta la industria eléctrica es la incertidumbre en la demanda de energía, que puede variar debido a múltiples factores como cambios en el comportamiento del consumidor, condiciones climáticas y eventos imprevistos. Esta incertidumbre requiere de métodos de pronóstico avanzados que puedan adaptarse a las dinámicas complejas y cambiantes del consumo energético. Sin una predicción adecuada, las empresas del sector pueden enfrentar costos elevados, ineficiencias en la planificación de la producción y dificultades para cumplir con los requisitos regulatorios.

En particular, el enfoque específico de este trabajo de grado es la predicción de la demanda de energía eléctrica en la región de Santander. El trabajo de grado se centra en evaluar y comparar diferentes modelos de pronóstico, específicamente Random Forest y Long Short-Term Memory (LSTM), para determinar cuál de ellos ofrece la mejor precisión en la estimación de la demanda de energía eléctrica en esta región.

Este trabajo de grado se organiza en cinco capítulos, cada uno de los cuales aborda aspectos específicos del estudio sobre el pronóstico de la demanda de energía eléctrica en Santander. A continuación, se ofrece una breve descripción de lo que el lector encontrará en cada capítulo:

En el capítulo de Descripción del Problema, se introduce el problema general que motiva la investigación: la necesidad de mejorar la precisión en el pronóstico de la demanda de energía eléctrica en Santander. Se exploran los desafíos que enfrenta el sector energético en la región, incluyendo las dificultades para gestionar la oferta y la demanda en un entorno caracterizado por la variabilidad de la demanda y las limitaciones en los modelos predictivos existentes. Este capítulo establece el contexto y la importancia del estudio, proporcionando una visión clara de por qué es necesario abordar el problema y las implicaciones de una mejora en los métodos de pronóstico.

Separadamente, un capítulo de Objetivos, define los objetivos principales del trabajo. Se establecen los propósitos generales y específicos de la investigación, incluyendo el objetivo principal de desarrollar y validar modelos de pronóstico para la demanda de energía eléctrica en Santander. También se detallan los objetivos secundarios, que abarcan la comparación de diferentes modelos predictivos y la evaluación de su desempeño en el contexto específico de la región. Este capítulo proporciona una guía clara sobre lo que se espera lograr a través del estudio y cómo se medirá el éxito.

Con el capítulo de Fundamentación Teórica, se aborda la base teórica sobre la que se construye la investigación. Se revisan los conceptos clave relacionados con el pronóstico de la demanda de energía eléctrica, incluyendo los diferentes enfoques y técnicas utilizadas en el campo.

Se exploran los modelos tradicionales (Random Forest) y modernos (LSTM), proporcionando una comprensión profunda de sus fundamentos, ventajas, y limitaciones. Este capítulo proporciona el marco conceptual necesario para entender la metodología empleada y los resultados obtenidos.

Se prosigue con un capítulo que detalla la Metodología empleada para llevar a cabo el estudio. Se describen los procedimientos seguidos para la recolección y análisis de datos, la selección de modelos predictivos, y la implementación de las técnicas de pronóstico. Se incluyen

detalles sobre el uso de herramientas y software, como PyCaret y Google Colab, y se explican los métodos de evaluación del desempeño de los modelos. Este capítulo ofrece una explicación exhaustiva de cómo se realizó el estudio, permitiendo la replicación y validación de los resultados por otros investigadores.

Finalmente, se presenta un capítulo de los resultados obtenidos a partir de la aplicación de los modelos de pronóstico seleccionados. Se analizan y comparan los pronósticos generados por los modelos Random Forest y LSTM, tanto en términos de precisión como de utilidad práctica. Se incluyen gráficos, tablas y análisis detallados que ilustran el desempeño de cada modelo y su efectividad en la predicción de la demanda de energía eléctrica en Santander. Este capítulo también discute las implicaciones de los hallazgos, las limitaciones del estudio, y las recomendaciones para futuras investigaciones.

Este enfoque permitirá no solo entender mejor la dinámica de la demanda de energía en Santander, sino también ofrecer herramientas y recomendaciones para mejorar la precisión en la previsión de la demanda eléctrica en contextos similares.

1. Descripción del Problema

El pronóstico de la demanda de energía eléctrica es un tema crucial para la planificación y operación del sistema eléctrico santandereano. La precisión de las predicciones es fundamental para garantizar la seguridad energética, optimizar la generación y distribución de energía, y minimizar los costos del sistema.

El sector energético de Santander ha experimentado una transformación significativa en las últimas décadas, impulsada por el crecimiento económico, la expansión de la infraestructura eléctrica y un interés creciente en la incorporación de fuentes de energía renovable. En este

contexto, la capacidad para pronosticar de manera precisa la demanda de energía eléctrica se ha vuelto fundamental para garantizar un suministro eficiente y sostenible.

Santander, siendo un país con una diversidad geográfica y climática única, enfrenta desafíos particulares en la predicción de la demanda eléctrica. Factores como la estacionalidad climática, la variabilidad geográfica y la creciente adopción de tecnologías de energía renovable introducen complejidades adicionales en el proceso de pronóstico.

En la última década, se han llevado a cabo diversos esfuerzos para mejorar los métodos tradicionales de pronóstico, incorporando las tecnologías que emergen con cada quinquenio. Investigadores, instituciones académicas y empresas del sector energético han contribuido con estudios y proyectos que buscan optimizar la precisión de los pronósticos, adaptándolos a la realidad santandereana. Algunos de estos estudios se presentan en la Tabla 1.

Tabla 1.

Relación de Estudios Representativos en Santander de Métodos de Pronóstico de Demanda de Energía

Estudio	Autores	Propósito	Alcance	Resultados
Modelo de predicción de la demanda de energía eléctrica en Santander por regresiones múltiples	Grimaldo (2012)	Desarrollar un modelo de regresión lineal múltiple para la predicción anual de la demanda de energía eléctrica.	Demanda anual de energía eléctrica a nivel nacional.	R ² de 0.94.
Estudio del pronóstico de la demanda de energía eléctrica, utilizando modelos de series de tiempo	Murillo, Trejos y Olaya (2003)	Evaluar el uso de modelos ARIMA y SARIMA para la predicción de la demanda de corto plazo.	Demanda de energía eléctrica en la ciudad de Pereira.	Error promedio de menos del 5%.
Predicción de demanda de energía en Santander mediante un sistema de inferencia difuso neuronal	Hurtado y Aguado (2005)	Evaluar el desempeño de diferentes técnicas de aprendizaje automático para la predicción de la	Mercado eléctrico santandereano.	Error promedio de menos del 4%.

		demanda de corto plazo.		
Avances recientes en la predicción de la demanda de electricidad usando modelos no lineales	Rueda, Velásquez y Franco (2011)	Desarrollar un modelo para la predicción de precios de energía eléctrica en mercados con alta participación de fuentes renovables.	Demanda de energía eléctrica a nivel nacional.	Error promedio de menos del 3%.
Inteligencia artificial en pronóstico de demanda de energía eléctrica: una aplicación en optimización de recursos energéticos	Sarmiento y Villa (2008)	Aplicación de la Inteligencia Artificial naciente en la década pasada como una primera aproximación al pronóstico	Mercado eléctrico santandereano	Error promedio de menos del 2%

Fuente: artículos consultados de la base de datos Science Direct

Nota: El cuadro solo es una muestra de estudios representativos, no constituyen el censo de los mismos

Cabe aclarar, que las instituciones colombianas encargadas del pronóstico de demanda de energía eléctrica en Colombia, como el Centro Nacional de Despacho (CND), vienen utilizando técnicas de series de tiempo como las tradicionales Medias Móviles, ARIMA, SARIMA, y técnicas de “machine learning”, de las cuales estas últimas algunas se tratan en este proyecto (Montoya, 2021), pero no se conoce del uso del Random Forest.

Ahora, el país está experimentando una transición hacia una matriz energética más sostenible, con un aumento en la adopción de fuentes de energía renovable. La intermitencia inherente a algunas de estas fuentes, como la solar y la eólica, requiere enfoques más sofisticados para prever su contribución a la red eléctrica.

Finalmente, la pregunta de desarrollo es: ¿Cómo el método Random Forest a través de la herramienta PyCaret pueden ser utilizados para la aplicación de inteligencia artificial en el pronóstico de demanda de la energía eléctrica en Santander?

2. Objetivos

2.1 Objetivo General

Implementar una Herramienta de Pronóstico de Demanda de Energía Eléctrica en Santander Utilizando el Método de Random Forest y Basada en PyCaret

2.2 Objetivos Específicos

- Recolectar datos históricos de la demanda de energía eléctrica en Santander como insumo para los modelos de inteligencia artificial a evaluar mediante bases de datos online

- Seleccionar una técnica de mejor ajuste de estimación de demanda, basada en inteligencia artificial sobre los datos históricos recolectados de la demanda de energía eléctrica en Santander, utilizando la herramienta PyCaret, para ser comparada con la técnica Random Forest.

- Evaluar mediante medidas de desempeño para modelos de pronóstico las técnicas aplicadas para la estimación y pronóstico de la demanda de energía eléctrica en Santander, utilizando la herramienta PyCaret.

3. Fundamentación Teórica

3.1 Estado del Arte

3.1.1 Métodos Tradicionales de Pronósticos.

Se han utilizado principalmente cuatro tipos de métodos de pronóstico para los mercados de electricidad: métodos de persistencia, métodos físicos, métodos estadísticos y métodos basados en inteligencia artificial (Inman, Pedro y Coimbra, 2013). Cuando se utilizan métodos de persistencia, se considera que las observaciones futuras tienen los mismos valores que las de las instancias actuales. Debido a la simplicidad e ingenuidad de estos métodos, tienen aplicaciones limitadas en los procesos de toma de decisiones en Mercados de Energía Eléctrica (MEE) y generalmente se usan solo para probar la precisión del pronóstico de otros métodos (Croonenbroeck y Stadtmann, 2019). Los métodos físicos, por otro lado, requieren un modelado matemático complejo de entornos en los que se gobiernan variables de interés. Por ejemplo, en el caso de los mercados de electricidad, si se desea predecir los precios, implicaría diseñar un modelo complejo de reglas de mercado y comportamientos de los actores del mercado (Luo y Miao, 2019).

En los métodos estadísticos, los modelos se diseñan utilizando principios de estadística y se extraen inferencias de observaciones históricas (Aggarwal, Saini y Kumar, 2009). El uso de estos métodos en MEE no proporciona resultados precisos ya que se ignoran muchos factores influyentes como la carga, el precio de generación y el costo del combustible, etc. (Cai, et al, 2015). Los métodos estadísticos que utilizan técnicas autorregresivas implementan pronosticadores lineales simples lo que les impide capturar las no linealidades del sistema. Olsson y Söder (2008) no consideraron de manera explícita la estructura del mercado en el modelo estadístico propuesto. En cambio, ellos utilizaron árboles de escenarios para generar una gran cantidad de escenarios de mercado representativos. Pero tales representaciones no siempre son posibles o deseadas.

3.1.2 Aplicaciones Clave De Los Métodos De Pronóstico Basados En IA.

Los métodos basados en IA presentan una mayor precisión y cumplen mejores requisitos computacionales en términos de rendimiento en comparación con los métodos tradicionales. Por ejemplo, en las redes neuronales artificiales (RNA), la detección de tendencias y patrones es más fácil que los modelos estadísticos. También presentan una mejor capacidad en el manejo de clasificación, agrupación, estimación, reconocimiento, etc. También pueden manejar dependencias no lineales, una característica que no es posible en métodos estadísticos convencionales (Wang, Tang y Xu, 2019). Por lo tanto, en Georgilakis (2022) los métodos basados en IA se presentan como una solución a los problemas de previsión en los mercados eléctricos.

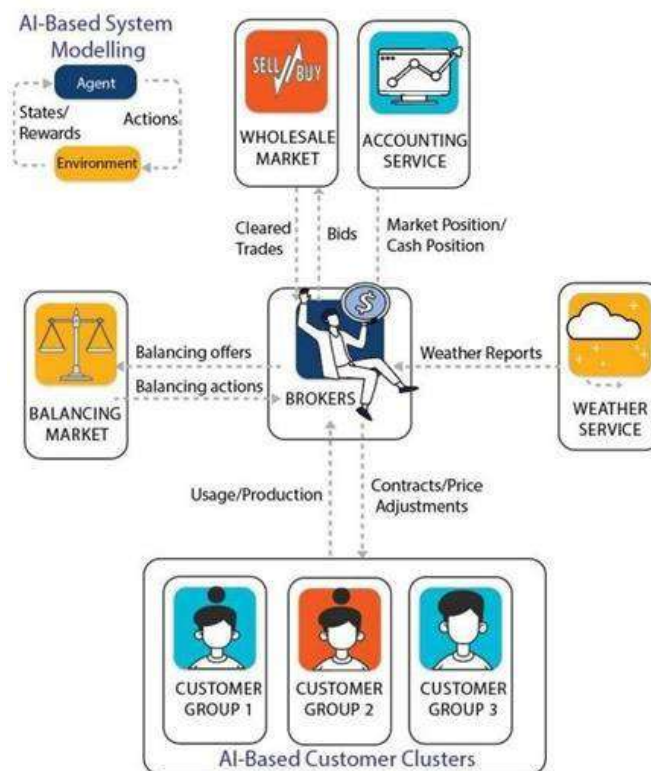
También existen algunas deficiencias en los modelos de IA. Por ejemplo, en Razak et al. (2021), se puede ver que cuando se utilizaron redes neuronales y modelos de lógica difusa en los pronósticos de los mercados de electricidad, experimentaron problemas de generalización y demostraron ser inadecuados para datos invisibles. Pero, afortunadamente, otros enfoques basados en IA, como las máquinas de vectores de soporte (SVM), pueden ayudar en tales casos al reducir las complejidades del modelo. En Razak et al (2021) y, Negnevitsky, Mandal y Srivastava (2019) un entrenamiento más pequeño de datos para pronósticos de precios utilizando SVM ayudó a resolver los inconvenientes de las redes neuronales. En esta sección, se investigan las aplicaciones de métodos basados en IA en MEE para diferentes roles.

Dado que el equilibrio de los mercados implica interacciones complejas entre numerosos participantes, la simulación de MEE como modelos de múltiples agentes desempeña un papel crucial en la comprensión del mercado. Esta comprensión ayuda a evaluar el impacto económico de los desequilibrios sistemáticos, como se ve en Ansarin, Ketter y Collins (2016). En la literatura, se ha propuesto una plataforma basada en el aprendizaje por refuerzo impulsada por IA conocida

como competencia de agentes comerciales de potencia eléctrica (PowerTAC), la cual simula la estructura de los MEE, que se ajusta después de cada paso de la simulación de acuerdo con las cambiantes demandas del mercado. PowerTAC incorpora pronósticos de producción de fuentes de energía, pronósticos meteorológicos y pronósticos de precios para regular los patrones de comportamiento de los agentes. Esta técnica se ha utilizado en Weerdt, Ketter y Collins (2021), donde se han desarrollado metodologías de precios y estrategias comerciales para corredores involucrados en transacciones MEE.

Figura 1.

Modelado de Sistemas de Pronóstico de Mercado Basado en IA



Fuente: Weerdt, Ketter y Collins (2021)

Las técnicas basadas en IA también ayudan a los intermediarios en la agrupación clasificar a los clientes en diferentes grupos según sus necesidades. En Weerdt, Ketter y Collins (2021), tales agrupaciones ayudaron a los corredores a formular una variedad de mecanismos de fijación de precios para satisfacer los diferentes requisitos de diferentes grupos de clientes. También les ayudó a obtener mayores recompensas al superar a los corredores que utilizaron estrategias predeterminadas o aleatorias. En la Figura 1. se ilustra el modelo del sistema MEE basado en IA. El agente es un corredor que aprende del entorno, que incluye varias entidades como el mercado de equilibrio, los clientes, los servicios meteorológicos y el mercado mayorista. Con base en los aportes aprendidos del entorno, el corredor toma decisiones sobre el equilibrio de ofertas, ajustes de precios y ofertas de mercado. En la Figura 1. también se ilustra la agrupación de clientes basada en IA.

Además, estos modelos de sistemas basados en IA también ayudan a los actores del mercado a predecir las respuestas de los competidores. En Santos, Pinto, Vale y Horais (2022) se generaron múltiples escenarios de mercado para ayudar a los participantes del mercado a predecir las acciones del competidor. Por lo tanto, los métodos basados en IA encuentran un amplio uso en el modelado de MEE. Ayudan a los actores del mercado a desarrollar estrategias comerciales que maximicen las ganancias. Estas simulaciones de sistemas no son posibles si se utilizan métodos físicos en lugar de métodos basados en IA, ya que se caracterizan por una alta complejidad computacional que dificulta su uso en predicciones a corto plazo.

3.2 Marco Teórico

3.2.1 Concepto de Inteligencia Artificial

La inteligencia artificial se define como la capacidad de las máquinas para realizar tareas que normalmente requieren de la inteligencia humana. En el contexto de pronósticos de demanda eléctrica, las técnicas de aprendizaje automático y procesamiento de lenguaje natural son esenciales. El aprendizaje automático permite a los modelos mejorar su rendimiento a medida que son expuestos a más datos, mientras que el procesamiento de lenguaje natural facilita la interpretación de información textual relevante.

3.2.2 Redes Neuronales y Machine Learning

La inteligencia artificial (IA) representa la capacidad de las máquinas para realizar tareas que generalmente requieren inteligencia humana. Este campo multidisciplinario se centra en el desarrollo de algoritmos y modelos que permiten a las máquinas aprender de datos, razonar, comprender el lenguaje natural y adaptarse a nuevas situaciones. Dentro de la IA, el aprendizaje automático (Machine Learning) es una rama crucial que implica la construcción de modelos capaces de mejorar su rendimiento a medida que son expuestos a más datos.

La aplicación de la inteligencia artificial en la estimación y pronóstico de la demanda de energía eléctrica ha cobrado relevancia debido a la necesidad de abordar la complejidad de los patrones de consumo, la creciente integración de fuentes renovables y la demanda cada vez mayor de precisión en la planificación energética.

Las Redes Neuronales Artificiales (ANN) son componentes fundamentales de la inteligencia artificial que han demostrado ser eficaces en la predicción de series temporales, como la demanda de energía eléctrica. La estructura de una ANN imita la red neuronal del cerebro humano y consta de capas de nodos interconectados.

Capa de Entrada (Input Layer): Esta capa recibe las variables de entrada, como datos históricos de consumo, condiciones climáticas y factores económicos.

Capas Ocultas (Hidden Layers): Estas capas procesan la información de la capa de entrada mediante la aplicación de pesos y funciones de activación. La cantidad de capas y nodos en cada capa depende de la complejidad del problema y la arquitectura específica elegida.

Capa de Salida (Output Layer): La capa de salida produce la predicción final. En el pronóstico de demanda, podría representar la estimación futura de consumo eléctrico.

Matemáticamente, el proceso de una ANN implica operaciones en cada nodo y capa. Consideremos una red neuronal de una sola capa oculta para simplificar, La operación en un nodo se describe como:

$$a = f\left(\sum_{i=1}^n w_i x_i + b\right)$$

La operación en una capa se expresa como:

$$A^{(l)} = f(W^{(l)} \cdot X^{(l-1)} + B^{(l)})$$

Donde:

a : Activación del nodo.

f : Función de activación (como la función sigmoide o ReLU).

w_i : Peso asociado al enlace entre el nodo de entrada i y el nodo actual.

x_i : Valor de entrada asociado al nodo i .

b : Término de sesgo.

$A^{(l)}$: Activación de la capa l .

$W^{(l)}$: Matriz de pesos para la capa l .

$X^{(l-1)}$: Vector de activaciones de la capa anterior.

$B(l)$: Vector de términos de sesgo para la capa l .

El aprendizaje automático abarca diversas técnicas, siendo la regresión y la clasificación las más aplicadas en el pronóstico de demanda eléctrica. La regresión lineal, por ejemplo, modela la relación entre variables independientes y la demanda eléctrica, permitiendo proyecciones numéricas. Por otro lado, los algoritmos de clasificación facilitan la categorización de datos, útil para segmentar la demanda en periodos específicos.

Los modelos de machine learning (aprendizaje automático) son herramientas fundamentales en el campo de la inteligencia artificial para predecir y clasificar datos basándose en patrones aprendidos. Se dividen en dos categorías principales: modelos supervisados y no supervisados. A continuación, se describe la estructura general y el funcionamiento de los modelos de machine learning.

1. Modelos Supervisados:

- **Regresión Lineal:** Utiliza como estructura una línea que mejor se ajusta a los datos de entrada.

$$y = mx + b$$

Donde y es la variable a predecir, x es la variable de entrada, m es la pendiente y b es la intersección con el eje y .

2. Modelos No Supervisados:

- **K-Means:** Una estructura que agrupa los datos en k clusters.

$$J = \sum_{i=1}^k \sum_{j=1}^{n_i} \|\mathbf{x}_j - \mu_i\|^2$$

Donde J es la función objetivo, x_j son los datos, μ_i son los centroides y n_i es el número de puntos en el cluster i .

3. Análisis de Componentes Principales (PCA):

Es una técnica que reduce la dimensionalidad de los datos proyectándolos en un nuevo espacio.

$$Z = X \cdot W$$

Donde Z es el conjunto de datos transformado, X es la matriz original y W son los eigenvectores.

3.2.5 Herramientas Informáticas en Aplicaciones de IA

En el vasto campo de la inteligencia artificial (IA), el desarrollo de modelos eficientes y precisos depende en gran medida de las herramientas y plataformas elegidas por los expertos. Entre los frameworks de desarrollo más destacados, TensorFlow y PyTorch han ganado un reconocimiento significativo debido a sus capacidades avanzadas y su flexibilidad en la implementación de modelos de IA.

TensorFlow, desarrollado por Google, se ha consolidado como una opción líder para el desarrollo de modelos de aprendizaje profundo. Su estructura flexible de gráficos computacionales permite construir y entrenar modelos de manera eficiente. Además, TensorFlow ofrece una amplia variedad de módulos y herramientas para abordar tareas específicas en el campo de la IA, desde clasificación de imágenes hasta procesamiento de lenguaje natural.

Por otro lado, PyTorch ha ganado terreno debido a su enfoque más dinámico y amigable para los desarrolladores. Su estructura basada en grafos dinámicos facilita la experimentación y depuración, lo que lo hace atractivo para investigadores y profesionales que buscan una mayor flexibilidad en el diseño de modelos. La comunidad activa de PyTorch ha contribuido al desarrollo de bibliotecas y extensiones, expandiendo su funcionalidad.

El entorno de desarrollo juega un papel crucial en la implementación y análisis de modelos de inteligencia artificial. Jupyter Notebooks y Google Colab se han convertido en opciones populares, cada una con sus propias ventajas.

Jupyter Notebooks proporciona un entorno interactivo que permite combinar código, visualizaciones y texto explicativo en un solo documento. Su interfaz basada en navegador facilita la experimentación y la colaboración, convirtiéndolo en una opción predilecta para científicos de datos y desarrolladores. La capacidad de ejecutar celdas de código individualmente simplifica la depuración y el análisis paso a paso.

Google Colab, por otro lado, ofrece un entorno de ejecución de Notebooks en la nube con acceso gratuito a GPUs, lo que acelera significativamente el entrenamiento de modelos complejos. Colab se integra estrechamente con Google Drive, facilitando el almacenamiento y compartición de Notebooks. Esta plataforma es especialmente valiosa para proyectos de mayor envergadura que requieren potencia de cálculo adicional.

En la implementación de modelos de inteligencia artificial, Python ha emergido como el lenguaje dominante. Su sintaxis clara y legible, junto con una amplia variedad de bibliotecas como NumPy, Pandas y Scikit-learn, hacen de Python una elección natural. R también mantiene su relevancia, especialmente en entornos estadísticos y análisis de datos.

La programación de modelos en TensorFlow implica la definición de un grafo computacional que representa las operaciones entre nodos. Utilizando la interfaz de alto nivel Keras, los desarrolladores pueden construir modelos de manera intuitiva. El modelo matemático se expresa a través de capas, funciones de activación y funciones de pérdida. La compilación y el entrenamiento se llevan a cabo utilizando optimizadores y conjuntos de datos.

3.2.6 *PyCaret*

En el contexto actual del aprendizaje automático y la ciencia de datos, PyCaret se erige como una herramienta fundamental que optimiza y automatiza los procesos de modelado predictivo. Esta biblioteca de código abierto, desarrollada en Python, se caracteriza por su capacidad para simplificar el flujo de trabajo en proyectos de aprendizaje automático, abarcando desde la preparación de datos hasta la implementación de modelos. La integración de PyCaret con Google Colab, una plataforma de notebooks basada en la nube, potencia su accesibilidad y facilita su adopción tanto en entornos académicos como profesionales (Alí, 2020).

La arquitectura de PyCaret se fundamenta en un diseño modular que permite abordar diversos tipos de problemas de aprendizaje automático. Entre estos se incluyen la clasificación, regresión, agrupamiento, detección de anomalías y análisis de series temporales. Esta versatilidad se logra mediante la implementación de módulos especializados para cada tipo de tarea, los cuales encapsulan funcionalidades específicas y algoritmos optimizados (Moez, 2021). La estructura modular no solo facilita la expansión y mantenimiento del código, sino que también permite a los usuarios seleccionar y utilizar únicamente los componentes necesarios para su proyecto específico.

Un aspecto crítico en el desarrollo de modelos de aprendizaje automático es la preparación de datos, fase que PyCaret aborda con particular eficacia. La biblioteca incorpora una serie de funciones automatizadas para el manejo de valores faltantes, codificación de variables categóricas, escalado de características y selección de atributos. Estas operaciones se ejecutan de manera eficiente y con mínima intervención del usuario, lo que reduce significativamente el tiempo dedicado a la manipulación de datos y permite un enfoque más centrado en la interpretación de resultados y la toma de decisiones basadas en datos (Kumar, 2022).

En lo que respecta al entrenamiento y evaluación de modelos, PyCaret implementa un enfoque de "AutoML" (Aprendizaje Automático Automatizado) que revoluciona el proceso de selección y ajuste de modelos. Mediante una interfaz unificada, la biblioteca permite entrenar y comparar múltiples algoritmos de manera simultánea, generando métricas de rendimiento detalladas para cada modelo. Este enfoque no solo acelera el proceso de desarrollo, sino que también facilita la identificación de los modelos más adecuados para un conjunto de datos específico, optimizando así el rendimiento global del sistema predictivo (Chen et al., 2023).

La interpretabilidad de los modelos, un aspecto crucial en la aplicación práctica del aprendizaje automático, recibe especial atención en la arquitectura de PyCaret. La biblioteca integra diversas técnicas de visualización y análisis que permiten comprender el proceso de toma de decisiones de los modelos. Estas herramientas incluyen gráficos de importancia de características, parcelas de dependencia parcial y análisis SHAP (SHapley Additive exPlanations), proporcionando insights profundos sobre el comportamiento del modelo y facilitando la construcción de sistemas de IA explicables y confiables (Lundberg & Lee, 2017).

Desde una perspectiva de ingeniería de software, PyCaret se destaca por su interoperabilidad con otras bibliotecas prominentes en el ecosistema de ciencia de datos de Python. Su diseño permite una integración fluida con pandas para manipulación de datos, scikit-learn para algoritmos de aprendizaje automático y matplotlib para visualizaciones. Esta sinergia facilita la creación de flujos de trabajo complejos y personalizados, adaptándose a las necesidades específicas de cada proyecto (Géron, 2022).

3.2.7 *Random Forest*

Random Forest es un algoritmo de aprendizaje supervisado utilizado para tareas de clasificación y regresión. Se basa en la construcción de múltiples árboles de decisión durante el

entrenamiento y la combinación de sus predicciones para obtener una salida final. La idea principal detrás de Random Forest es la de "ensamblar" múltiples árboles de decisión para reducir el sobreajuste y mejorar el rendimiento predictivo (Antoniadis, Lambert-Lacroix & Poggi, 2021).

Su formulación matemática se basa en (Antoniadis, Lambert-Lacroix & Poggi, 2021):

a) Construcción de Árboles de Decisión: Un árbol de decisión es una estructura jerárquica que consiste en nodos (representando características), bordes (representando reglas de decisión) y hojas (representando las etiquetas de clase o valores de regresión).

Se define un conjunto de características $X = \{x_1, x_2, \dots, x_n\}$ y un conjunto de etiquetas de clase $Y = \{y_1, y_2, \dots, y_n\}$. Cada nodo del árbol se divide utilizando una regla de decisión que maximiza la pureza de las muestras en los nodos resultantes.

b) Construcción del Bosque Aleatorio: Se generan múltiples árboles de decisión de forma independiente. Durante el entrenamiento de cada árbol, se toma una muestra aleatoria con reemplazo (bootstrap) del conjunto de datos de entrenamiento. Además, en cada división de nodo, se selecciona un subconjunto aleatorio de características. Estas dos técnicas introducen aleatoriedad en la construcción de los árboles, lo que ayuda a decorrelacionar los árboles y reduce el sobreajuste.

c) Predicción Final: Para la clasificación, las predicciones finales se obtienen por voto mayoritario entre los árboles individuales. Es decir, la clase más común predicha por los árboles se selecciona como la predicción final. Para la regresión, las predicciones finales se obtienen promediando las predicciones de todos los árboles.

Entre las ventajas se observa (Antoniadis, Lambert-Lacroix & Poggi, 2021):

a) Buena capacidad para manejar características numéricas y categóricas.

b) Resistente al sobreajuste debido a la técnica de ensamblaje y la aleatorización en la construcción de árboles.

Y entre sus limitaciones (Antoniadis, Lambert-Lacroix & Poggi, 2021):

a) Puede no ser tan eficiente para datos de alta dimensionalidad o datos con relaciones no lineales complejas.

b) No es tan interpretable como algunos otros modelos debido a la complejidad inherente de los árboles de decisión.

3.2.8 LSTM (Long Short-Term Memory)

En el ámbito de las redes neuronales recurrentes (RNN), el método de pronóstico LSTM (Long Short-Term Memory) se destaca como una arquitectura avanzada diseñada para abordar las limitaciones de las RNN tradicionales en el procesamiento de secuencias largas. Desarrollada originalmente por Hochreiter y Schmidhuber (1997), la arquitectura LSTM ha experimentado diversas mejoras y variaciones a lo largo de los años, consolidándose como una herramienta fundamental en tareas de predicción y análisis de series temporales.

La estructura fundamental de una unidad LSTM se compone de una celda de memoria y tres "puertas" (gates) que regulan el flujo de información: la puerta de entrada, la puerta de olvido y la puerta de salida. Esta configuración permite a la red mantener, actualizar o descartar información relevante a lo largo del tiempo, superando así el problema del desvanecimiento del gradiente que afecta a las RNN convencionales (Gers et al., 2000). La celda de memoria actúa como un repositorio de información a largo plazo, mientras que las puertas controlan qué información se almacena, se actualiza o se propaga a las capas subsiguientes de la red.

El proceso de pronóstico mediante LSTM se inicia con la preparación de los datos de entrada, que típicamente consiste en secuencias temporales normalizadas y estructuradas en

ventanas deslizantes. Cada ventana representa un conjunto de observaciones históricas utilizadas para predecir uno o más valores futuros. La longitud de estas ventanas y el horizonte de predicción son parámetros críticos que influyen significativamente en el rendimiento del modelo y deben ser cuidadosamente seleccionados en función de las características específicas del problema en cuestión (Siarni-Namini et al., 2019).

La arquitectura de una red LSTM para pronóstico generalmente consta de una o más capas LSTM seguidas de capas densas (fully connected). La capa de entrada recibe la secuencia temporal, mientras que las capas LSTM procesan la información secuencial, capturando dependencias a corto y largo plazo. Las capas densas finales se encargan de mapear las representaciones aprendidas por las capas LSTM a los valores de pronóstico deseados. La profundidad de la red, el número de unidades LSTM por capa y la configuración de las capas densas son hiperparámetros que requieren optimización para cada aplicación específica (Greff et al., 2017).

El entrenamiento de un modelo LSTM para pronóstico se lleva a cabo mediante el algoritmo de retro propagación a través del tiempo (BPTT), una extensión del algoritmo de retro propagación estándar adaptado para estructuras recurrentes. Durante este proceso, los pesos de la red se ajustan iterativamente para minimizar una función de pérdida, típicamente el error cuadrático medio (MSE) o el error absoluto medio (MAE) entre las predicciones del modelo y los valores reales. La optimización de los hiperparámetros, incluyendo la tasa de aprendizaje, el tamaño del lote y el número de épocas, es crucial para lograr un rendimiento óptimo y evitar problemas como el sobreajuste (Pascanu et al., 2013).

Una característica distintiva del método LSTM en el contexto de pronóstico es su capacidad para capturar y modelar dependencias temporales complejas y no lineales en los datos. Esta

propiedad lo hace particularmente adecuado para series temporales que exhiben patrones estacionales, tendencias a largo plazo o comportamientos cíclicos. Además, la arquitectura LSTM permite la incorporación de variables exógenas o características adicionales que pueden mejorar la precisión de las predicciones, facilitando así el desarrollo de modelos de pronóstico multivariados (Lim et al., 2021).

4. Metodología

4.1 Método

Fase 1. Recolección de Datos

Se llevó a cabo la recolección de datos históricos de la demanda de energía eléctrica en Santander. Se accedió a bases de datos en línea, como las proporcionadas por entidades gubernamentales y organizaciones del sector energético. En el apartado 5.1 Recolección de Datos Históricos, como parte de la presentación de cumplimiento del primer objetivo específico, se profundiza más sobre la recolección de datos. Los datos disponibles estuvieron dentro de la ventana temporal enero de 2000 a agosto de 2024.

Fase 2. Selección de Modelos de Inteligencia Artificial

Se realizó una revisión de la literatura para identificar modelos de inteligencia artificial aplicados en el pronóstico de demanda de energía eléctrica que puedan ser comparados con el método Random Forest. Se consideró comparar Random Forest con técnicas de inteligencia artificial (IA) como Redes Neuronales Artificiales (ANN), Máquinas de Soporte Vectorial (SVM), y modelos basados en algoritmos de aprendizaje profundo como LSTM (Long Short-Term Memory) y Transformer (ajustado mediante el proxy LightGBM).

Para seleccionar el mejor ajuste, se requiere evaluar el desempeño de los modelos utilizando las siguientes métricas:

- Error Absoluto Medio (MAE - Mean Absolute Error): Mide la magnitud promedio de los errores en un conjunto de predicciones, sin considerar su dirección. Es la media de las diferencias absolutas entre las predicciones y los valores reales.

- Error Cuadrático Medio (MSE - Mean Squared Error): Promedio de los errores al cuadrado, que da más peso a los errores grandes. Se calcula como la media de las diferencias cuadráticas entre las predicciones y los valores reales.

- Raíz del Error Cuadrático Medio (RMSE - Root Mean Squared Error): Es la raíz cuadrada del MSE. Proporciona una medida del error en las mismas unidades que la variable objetivo, lo que facilita su interpretación. Es más sensible a outliers que el MAE.

- Coeficiente de Determinación (R^2): Indica qué tan bien los datos predichos se ajustan a los datos observados. Representa la proporción de la varianza en la variable dependiente que es predecible a partir de la(s) variable(s) independiente(s). Varía entre 0 y 1, donde 1 indica un ajuste perfecto.

- Raíz del Error Logarítmico Cuadrático Medio (RMSLE - Root Mean Squared Logarithmic Error): Similar al RMSE, pero se aplica a los logaritmos de los valores predichos y reales. Es útil cuando se quiere penalizar más los errores de subestimación que los de sobreestimación, y cuando los datos tienen una distribución con cola larga.

- Error Porcentual Absoluto Medio (MAPE - Mean Absolute Percentage Error): Expresa el error como un porcentaje del valor real. Se calcula como la media de los errores porcentuales absolutos. Es útil para comparar el rendimiento entre diferentes conjuntos de datos, pero puede ser problemático cuando los valores reales son cercanos o iguales a cero.

Adicionalmente, fue necesario, primeramente, hacer un preprocesamiento de los datos que permitiera tener una base datos correctamente registrada, y luego si, aplicar el entrenamiento de los métodos de inteligencia artificial para que, utilizando las métricas de desempeño, seleccionar el mejor ajuste. Esto incluyó:

- *Transformación de Fechas*: Las fechas se transformaron para asegurar que usaban el mismo formato mm-dd-yy.

- *Normalización*: La cantidad demandada se normalizó para mejorar: mejorar la capacidad de predicción de los algoritmos de inteligencia artificial, favorecer la comparabilidad de los métodos, y reducir la influencia de valores atípicos.

- *Ingeniería de Características*: se utilizó, además de la transformación de normalización explicada anteriormente, la estabilización de varianzas y la linealización de relaciones, en especial la transformación logarítmica que permite manejar el crecimiento exponencial y la heteroscedasticidad observada. Las características polinomiales (Polynomial Features) permitieron capturar las relaciones no lineales entre la demanda y el tiempo, y la eliminación de multicolinealidad (Remove Multicollinearity) permitió reducir la varianza en las estimaciones de los parámetros predictores.

- *Uso de Hiperparámetros*: para establecer según el modelo, de manera óptima, el número de capas, unidades en cada capa, la tasa dropout, la longitud de secuencia de entrada, el número de árboles, número de términos autorregresivos, entre otros.

Nota: es importante anotar, que la librería de PyCaret se encarga de realizar todos los ajustes anteriormente mencionados, previa solicitud mediante los comandos aplicados.

Apoyándose en la tabla y figura siguiente que permiten ver en comparación las diversas medidas de desempeño sobre los métodos o modelos de inteligencia artificial aplicados, se procede a realizar la valoración.

Tabla 2.

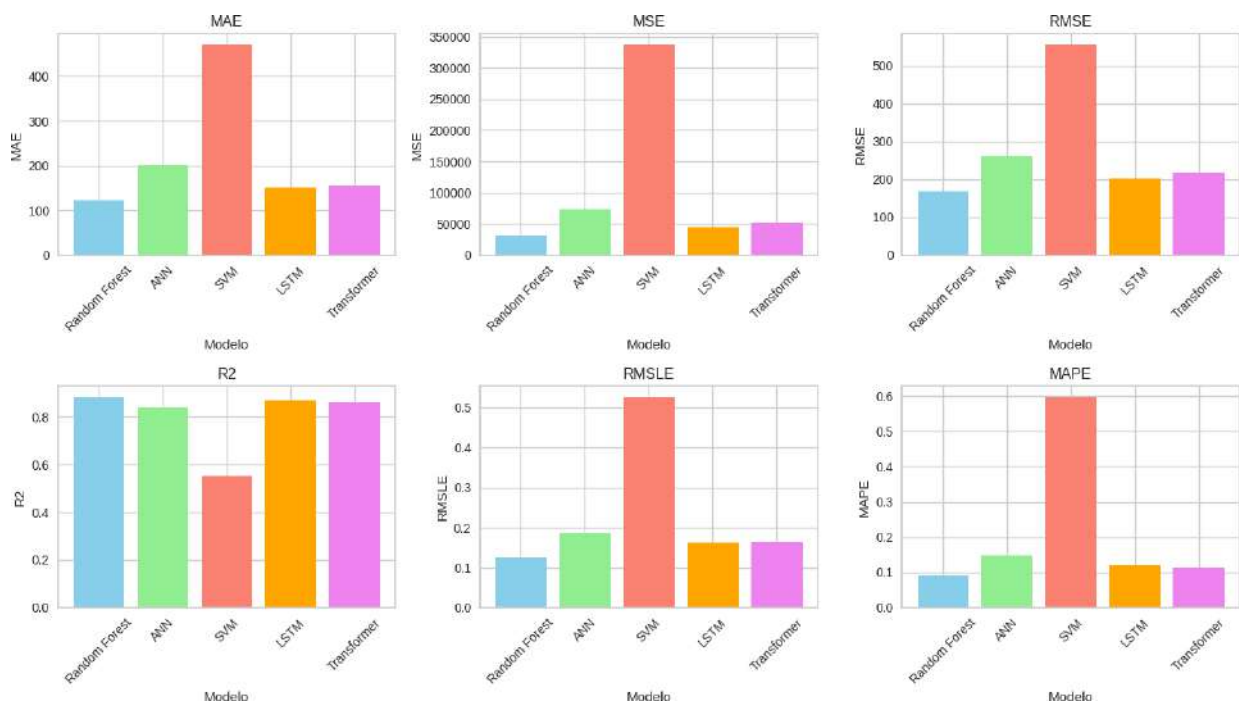
Comparación de Indicadores de Desempeño de los Modelos

Modelo	MAE	MSE	RMSE	R ²	RMSLE	MAPE
Random Forest	123.4968	30996.6557	168.5165	0.8832	0.1254	0.0913
Redes Neuronales	202.2574	74075.5219	260.4713	0.8369	0.1864	0.1478
SVM	471.4878	337892.0240	556.4378	0.5506	0.5269	0.5979
LSTM	151.6707	44802.9788	202.5787	0.8684	0.1621	0.1208
Transformer	155.1205	52016.9508	218.2945	0.8605	0.1639	0.1121

Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Figura 2.

Comparativa gráfica de los indicadores de rendimiento de los diferentes modelos



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Como se había venido analizando con el R^2 , efectivamente Random Forest tiene el R^2 más alto (0.8832), lo que indica que explica aproximadamente el 88.32% de la variabilidad en los datos. LSTM y Transformer siguen de cerca. SVM tiene el R^2 más bajo (0.5506), lo que sugiere que solo explica alrededor del 55.06% de la variabilidad, indicando un ajuste menos adecuado al modelo.

Lo anterior llevaría a sugerir inmediatamente que debería utilizarse el Random Forest para el pronóstico de la demanda.

Los demás indicadores muestran una favorabilidad similar para el método Random Forest, seguido por LSTM y Transformer. No obstante, por protocolo de análisis se describen sus comparativas a continuación:

- Error Absoluto Medio (MAE): Random Forest muestra el MAE más bajo (123.4968), seguido de cerca por LSTM (151.6707) y Transformer (155.1205). Esto indica que estos modelos tienen, en promedio, las menores desviaciones absolutas entre las predicciones y los valores reales. SVM tiene el peor desempeño con un MAE de 471.4878, lo que sugiere predicciones menos precisas.

- Error Cuadrático Medio (MSE): Random Forest presenta el MSE más bajo (30996.6557), lo que indica que tiene los errores más pequeños en general, especialmente considerando que el MSE penaliza más los errores grandes. SVM muestra el MSE más alto (337892.0240), lo que sugiere que este modelo está haciendo errores significativamente más grandes en sus predicciones.

- Raíz del Error Cuadrático Medio (RMSE): Siguiendo la tendencia del MSE, Random Forest tiene el RMSE más bajo (168.5165), lo que confirma su mejor desempeño en términos de precisión de predicción. LSTM y Transformer siguen con valores cercanos, mientras que SVM muestra el peor desempeño con un RMSE de 556.4378.

- Raíz del Error Logarítmico Cuadrático Medio (RMSLE): Random Forest muestra el RMSLE más bajo (0.1254), lo que indica que maneja bien los outliers y las variaciones en escala. SVM tiene un RMSLE notablemente alto (0.5269), sugiriendo que podría estar subestimando significativamente algunos valores.

- Error Porcentual Absoluto Medio (MAPE): Random Forest tiene el MAPE más bajo (0.0913 o 9.13%), indicando que, en promedio, sus predicciones se desvían un 9.13% de los valores reales. SVM muestra un MAPE muy alto (0.5979 o 59.79%), lo que sugiere predicciones poco confiables en términos porcentuales.

A partir de una comparación del coeficiente de determinación (R^2) entre modelos, se selecciona a el modelo LSTM como el único a ser comparado frente al Random Forest.

Otra consideración importante sobre esta fase, corresponde al uso de comandos de PyCaret para procesar los datos de tal manera que se adaptaran a las características de la serie de tiempo de la demanda de energía eléctrica de Santander. Sobre esto, metodológicamente fue necesario utilizar el ajuste de hiperparámetros y la “ingeniería de características” de los modelos. Entre las “Ingenierías de características” utilizadas, tenemos: `normalize`, `transformation`, `polynomial_features`, `remove_multicollinearity`. Entre la Ingeniería de características descartadas se encuentran: `feature_engineering`, `feature_selection`, `trigonometry_features`. En cuanto a Hiperparámetros: se utilizó el comando `tune_model` que compara técnicas como la búsqueda de cuadrícula (Grid Search) o la búsqueda aleatoria (Random Search) para encontrar los mejores hiperparámetros. También se utilizó la normalización (comando `normalize`) y la transformación de datos mediante logaritmos por ejemplo (comando `transformation`) que ayudan a mejorar el

rendimiento de los modelos. A continuación, se comparte la línea de código que configuro lo anteriormente enunciado:

```
# Configurar la sesión de PyCaret con los parámetros esenciales
reg_setup = setup(data=datos,
                  target='DemandaReal',
                  session_id=123,
                  normalize=True,
                  transformation=True,
                  polynomial_features=True,
                  remove_multicollinearity=True)

tuned_rf_model = tune_model(rf_model)
```

Es importante aclarar que se utiliza la palabra Estimación para la generación de datos por parte del modelo dentro del periodo para el que fue entrenado, y la palabra Pronóstico, para generar datos por el modelo para fechas inmediatamente posteriores al último día de entrenamiento. Por lo tanto, en esta fase, para obtener el R^2 se utilizaron datos “estimados” dentro del periodo de entrenamiento, y para la siguiente fase, se utilizan datos “pronosticados”.

Fase 3. Implementación de Técnicas para Pronóstico de Demanda

Se implementaron las técnicas de inteligencia artificial Random Forest y LSTM seleccionadas en la fase anterior para realizar los pronósticos para una semana de demanda, para un mes y para un año.

Al realizar el pronóstico para una semana se analizaron dos estrategias de *Rolling Horizon*: el *tradicional*, donde el entrenamiento utiliza todos los datos disponibles sin diferenciar o segmentarlos (Cuisinier, et al., 2022), y el *rollig horizon con segmentación diaria*, donde el entrenamiento de los datos se hace por segmentos (Cuisinier, et al., 2022), en el caso de una semana, se entrenan los datos del día lunes para pronosticar los lunes, y así sucesivamente hasta el domingo.

Ahora bien, la decisión de pronosticar una semana de demanda es una decisión coherente con la metodología definida para Colombia en la Resolución CREG 025 de 1995 y el Acuerdo del Consejo Nacional de Operación - CNO 1303 de 2020. En dicha resolución se establecen diferentes periodos de planeación; uno de ellos es el que denominan de corto plazo (1 semana). La entidad encargada de entregar el pronóstico para este corto plazo es el Centro Nacional de Despacho (CND), los días miércoles, entregando la predicción para los días lunes a domingo, tomando los datos hasta el viernes inmediatamente anterior.

Además de implementar las técnicas de pronósticos analizadas en este proyecto para una semana, se consideraron otros periodos de planeación. La CREG también ordena planeación (pronósticos) para el largo plazo (5 años), mediano plazo (1 año), y existe uno de muy corto plazo que es por horas. Sobre estos horizontes de planeación, se realizaron pronósticos para el periodo de mediano plazo – 1 año. También, por interés en la evaluación del desempeño de los modelos, se realizaron pronósticos a 1 mes.

Fase 4. Evaluación del Desempeño

Se evaluó el desempeño de cada técnica utilizando las métricas MAE, MSE, RMSE, R^2 , RMSLE, MAPE. Se aclara que tal evaluación se realizó en dos momentos: el primero, para comparar el ajuste de los datos estimados contra los datos reales dentro del periodo de entrenamiento años 2000 a 2023 que se evalúan en la fase 2; el segundo para comparar las dos mejores técnicas de pronóstico elegidas (Random Forest y LSTM) y que se utilizan en la fase 3, con los datos reales.

4.2 Código de PyCaret utilizado en el proyecto

De manera específica, la aplicación del método Random Forest y LSTM en este proyecto, utilizando PyCaret, se dio mediante el uso de los siguientes códigos específicos y su explicación (Ver tabla siguiente):

Tabla 3.

Código general de PyCaret utilizado en el proyecto y comandos específicos para los métodos Random Forest y LSTM

Código PyCaret	Explicaciones
<code>from pycaret.time_series import *</code>	Importa las funcionalidades específicas para series temporales de PyCaret.
<code>setup(data=datos_entrenamiento, target='DemandaReal', session_id=123, fold_strategy='timeseries', fold_shuffle=False, data_split_shuffle=False)</code>	Configura el entorno de PyCaret para el análisis de series temporales. Aquí se define el conjunto de datos, la variable objetivo, y se especifica que el método de validación es por series temporales sin barajado.
<code>compare_models()</code>	Compara múltiples modelos de series temporales y selecciona el mejor en función de métricas de rendimiento predeterminadas.
<code>create_model('rf')</code> <code>create_model('lstm')</code>	Crea un modelo de Random Forest y LSTM para series temporales.
<code>tune_model(model)</code>	Ajusta los hiperparámetros del modelo creado para optimizar su rendimiento.
<code>predict_model(model)</code>	Realiza predicciones utilizando el modelo ajustado.
<code>plot_model(model, plot='forecast')</code>	Genera un gráfico de las predicciones del modelo en función de la serie temporal.
<code>save_model(model, 'nombre_modelo')</code>	Guarda el modelo entrenado en un archivo con el nombre especificado para su uso futuro.
<code>load_model('nombre_modelo')</code>	Carga un modelo previamente guardado desde un archivo para hacer nuevas predicciones o continuar con su uso.
<code>evaluate_model(model)</code>	Evalúa el rendimiento del modelo con gráficos y métricas específicas para el modelo de serie temporal.
<code>get_metrics()</code>	Devuelve las métricas de rendimiento disponibles para los modelos en PyCaret.
<code>add_metric(name, metric_func)</code>	Añade una métrica personalizada para evaluar el rendimiento del modelo si es necesario.
<code>create_model('lstm')</code>	Crea un modelo de LSTM para series temporales.

Código PyCaret	Explicaciones
<code>tune_model('lstm')</code>	Ajusta los hiperparámetros del modelo LSTM para mejorar su rendimiento en las predicciones.
<code>predict_model('lstm')</code>	Realiza predicciones utilizando el modelo LSTM ajustado.

5. Resultados

5.1 Recolección de Datos Históricos y Estadísticas Descriptivas

5.1 Recolección de Datos Históricos

El primer objetivo específico consistió en recolectar datos históricos de la demanda de energía eléctrica en Santander. Para ello, se accedió a diversas bases de datos online que proporcionan información detallada sobre el consumo de energía en la región. Entre las fuentes de datos utilizadas se encuentran:

- **Sinergox:** solución informática en línea proveída por la empresa XM S.A. ESP que como lo indica su página web es “una empresa especializada en la gestión de sistemas de tiempo real, la administración del mercado de energía mayorista y el desarrollo de soluciones y servicios de energía e información”^{††}
- **Unidad de Planeación Minero – Energética (UPME):** Entidad del estado colombiano que dispone información energética, no solo eléctrica sino de otras fuentes como hidrocarburos.
- **Departamento Administrativo Nacional de Estadística (DANE):** Entidad del estado colombiano que dispone información estadística que incluye consumo de energía eléctrica.

De las tres fuentes de datos anteriores, finalmente, después de analizar los datos disponibles, se eligió los datos de Sinergox porque facilitaban su agrupación por departamentos en Colombia, siendo Santander el interés de este estudio, y porque disponía del dato exacto de demanda agregada, y no desagregada como lo tiene el DANE que usa segmentos industriales y no asegura la demanda total, o la UPME que dispone los datos pero ya tratados, es decir no los dispone en bruto sino mediante estadísticas resumidas de los mismos.

^{††} Definición textual de la página web <https://www.xm.com.co/nuestra-empresa/nosotros/quienes-somos>

Los datos disponibles por Sinergox corresponden a la demanda total entre las fechas 1-Ene-2000 en MW-h y para lo corrido del año 2024 (enero a agosto). Para efectos de este proyecto, dado que se desarrolló durante el transcurso del año 2024, era tomar como límite los datos hasta 31-Dic-2023. El link utilizado para extraer los datos fue el siguiente:

<https://sinergox.xm.com.co/dmnd/Paginas/Informes/DemandaRealDptoUNR.aspx>

Para la demanda real del periodo enero a agosto de 2024 se descargó de:

<https://www.xm.com.co/consumo/informes-demanda/indicadores-de-pronosticos-oficiales-de-demanda>

5.2 Estadísticas Descriptivas

Para una descripción de la serie temporal de la demanda de energía eléctrica en Santander, se realiza a continuación un análisis básico de estadísticas descriptivas.

Figura 3.

Pantallazo de Estadísticas Descriptivas Básicas de los datos a analizar

	DemandaReal
count	8766.000000
mean	1821.701805
std	956.178747
min	69.284300
25%	1018.293980
50%	1969.671690
75%	2578.269297
max	4125.729570


Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

La figura anterior presenta las estadísticas descriptivas de la demanda de energía eléctrica medida en MW/h. Se puede observar que en promedio por día se han consumido 1821 MW/h en el departamento de Santander en el periodo analizado (2000-2023) con una desviación estándar de 956 MW/h, que corresponden a un coeficiente de variación del 52.5%, lo que sugiere que hay

una alta variación en los datos. Esto puede explicarse como se verá más adelante que estos datos tienen una tendencia creciente.

Figura 4.

Histograma de Frecuencias de los datos




Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

El histograma de la figura anterior indica que los datos tienen multimodalidad, es decir, no existe un único rango de valores que representen un máximo, sino que existen varios rangos, hecho que sugiere lo que se ha comentado anteriormente que exista alguna tendencia. Lo que efectivamente se visualiza con claridad en la figura de la página siguiente, donde el diagrama de dispersión de los datos, mostrados en secuencia temporal, señalan una tendencia creciente de los mismos con alta variabilidad por días.

Figura 5.

Diagrama de Dispersión de los datos



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Las características principales de esta serie temporal de demanda de energía eléctrica en Santander entre 2000 y 2023 se resumen en:

1. **Tendencia creciente:** La serie muestra una clara tendencia al alza a lo largo del período, lo que indica un aumento general en la demanda de energía eléctrica. Esto podría atribuirse al crecimiento económico, aumento de la población, o mayor electrificación de la región.

2. **Estacionalidad:** Se observan patrones repetitivos a lo largo del tiempo, lo que sugiere una fuerte componente estacional. Esto podría estar relacionado con ciclos anuales de consumo energético debido a factores climáticos o patrones de actividad económica.

3. **Volatilidad:** La serie presenta una considerable variabilidad a corto plazo, con fluctuaciones diarias y semanales significativas. Esto es típico en series de demanda energética y

puede estar influenciado por factores como días laborables vs. fines de semana, o eventos especiales.

4. Cambios estructurales: Se pueden observar algunos cambios abruptos en el patrón de la serie, particularmente alrededor de 2004 y 2012. Estos podrían indicar cambios importantes en la infraestructura energética, políticas de consumo, o eventos económicos significativos.

5. Aumento de la variabilidad: En los últimos años, especialmente desde 2020, se observa un incremento en la amplitud de las fluctuaciones. Esto podría estar relacionado con la pandemia de COVID-19 y sus efectos en los patrones de consumo energético.

6. Valores atípicos: Se pueden identificar varios picos y valles extremos, particularmente en los años más recientes. Estos podrían representar eventos excepcionales como cortes de energía, condiciones climáticas extremas, o grandes eventos que afectan el consumo energético.

7. No linealidad: La relación entre el tiempo y la demanda no parece ser perfectamente lineal, lo que sugiere la presencia de factores complejos que influyen en la demanda energética.

8. Heteroscedasticidad: La varianza de la serie parece cambiar con el tiempo, siendo mayor en los períodos más recientes. Esto es importante para considerar en la modelación estadística.

5.2 Aplicación y Evaluación de Desempeño de Técnicas para Estimación y Pronóstico de Demanda

Como se mencionó en la metodología, la aplicación de técnicas de estimación y pronóstico de demanda incluye la fase 2 y la fase 3 de dicha metodología. La primera para seleccionar un modelo para ser comparado con Random Forest a partir de su mejor ajuste de los datos estimados frente a los datos reales, y la segunda para implementar estas dos técnicas de pronóstico. Dado que la selección se desarrolló dentro de la sección de metodología, este apartado está conformado por

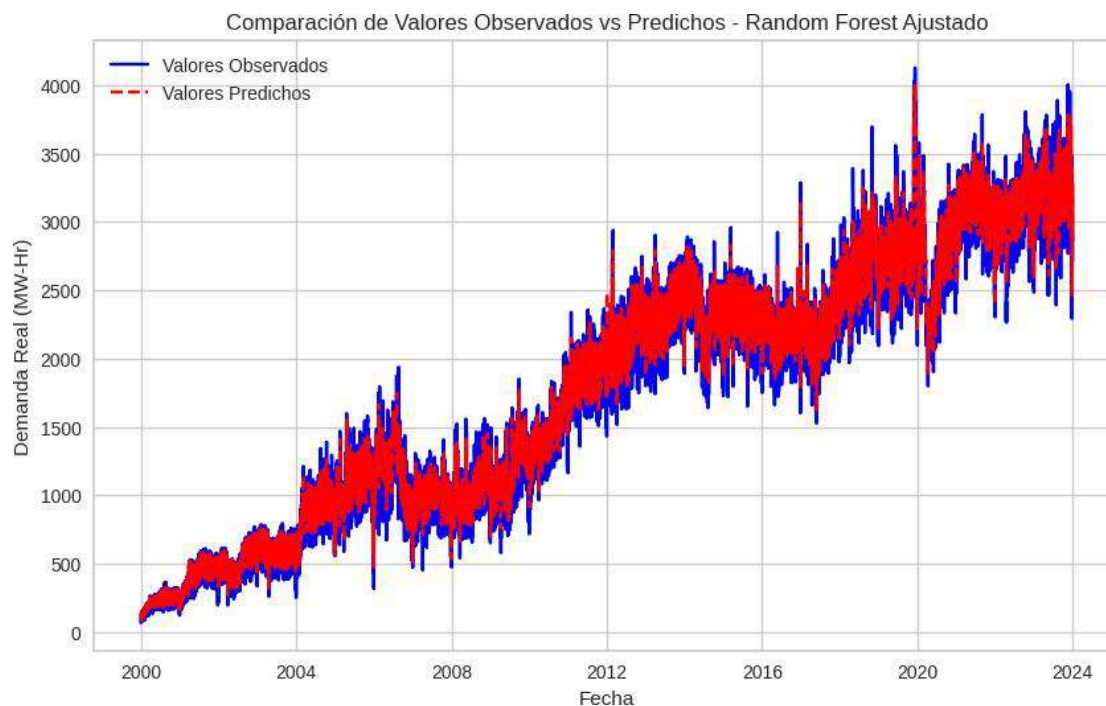
la implementación de las técnicas pronóstico de la demanda. La Fase 4 de la metodología (Evaluación de Desempeño, que además es cumplimiento del tercer objetivo específico) se incluye en el desarrollo del apartado mencionado.

5.2.1.3 Descripción del Modelo LSTM Elegido Como Mejor Ajuste y Random Forest Como Métodos Para Pronosticar la Demanda de Energía Eléctrica en Santander

Se inicia la descripción de los modelos con Random Forest. En la figura siguiente se presenta en color rojo, las estimaciones obtenidas utilizando el modelo entrenado en el periodo 2000-2023.

Figura 6.

Ajuste con Random Forest



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Se puede observar, que el modelo Random Forest sigue con muy buena aproximación visual los diferentes movimientos aleatorios de la demanda. Lo que hace parecer que es un buen modelo. De manera específica, los valores de medida de desempeño obtenidos se presentan en la siguiente tabla, donde se evidencia lo que visualmente se aprecia, que el ajuste, medido con el R^2 es de 0.8832, que puede considerarse un buen ajuste. Los demás valores de desempeño sólo pueden ser evaluados al compararlos con los demás modelos, lo cual se hace más adelante.

Tabla 4.

Medidas de desempeño del modelo Random Forest

MAE	MSE	RMSE	R^2	RMSLE	MAPE
123.4968	30996.6557	168.5165	0.8832	0.1254	0.0913

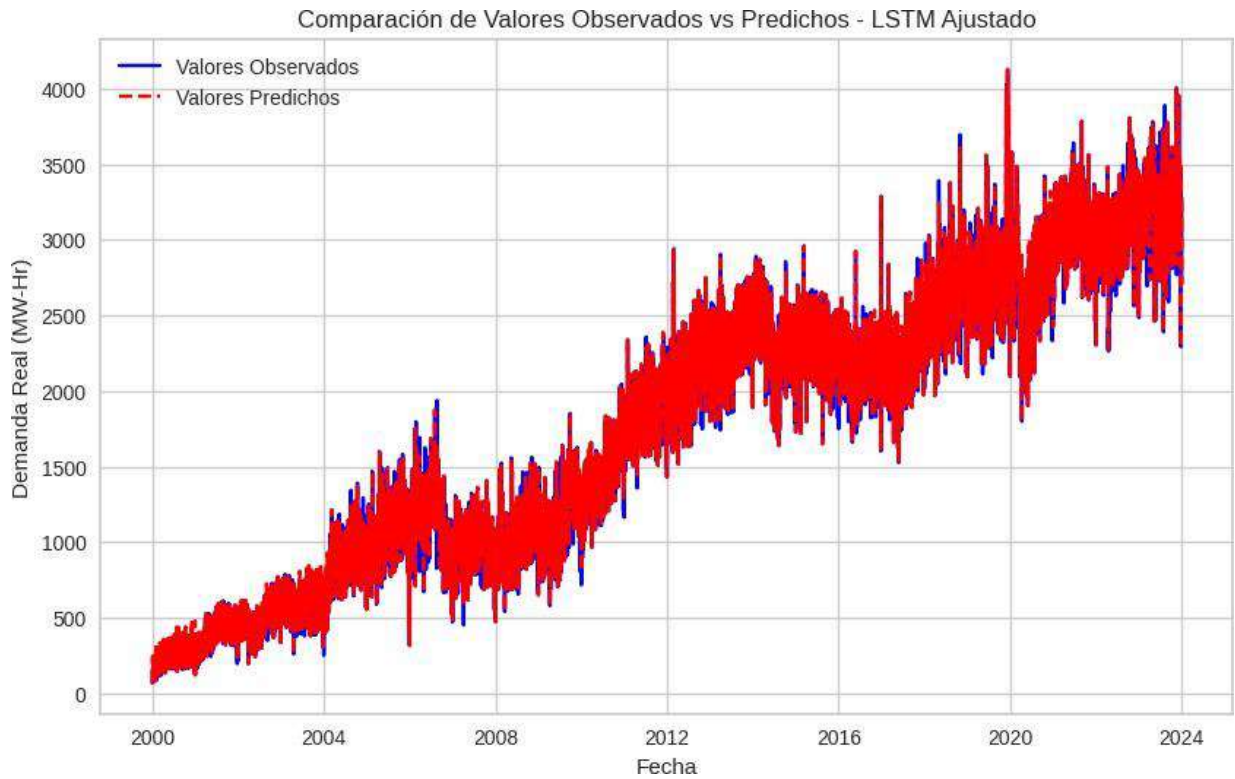
Nota: Elaboración propia utilizando PyCaret en Google Colab.

El método (Random Forest) mostró el mejor desempeño en todas las métricas evaluadas, es capaz de capturar relaciones no lineales complejas, lo cual es evidente en la serie temporal que muestra variaciones irregulares y tendencias cambiantes; puede manejar bien los outliers y las fluctuaciones bruscas que se observan en la serie, especialmente después de 2016. Su baja tasa de error (MAE, MSE, RMSE) y alto R^2 indican una buena capacidad para ajustarse a los datos sin sobreajuste excesivo.

Ahora, se revisa el ajuste del modelo LSTM, donde la figura siguiente permite observar cómo los datos de demanda estimada con dicho modelo (color rojo) siguen con fidelidad, visualmente hablando, a los datos de la demanda histórica real, sugiriendo un buen ajuste. Hecho que se corrobora con la medida de desempeño $R^2 = 0.8684$ que es tan solo, un poco menor a la del modelo Random Forest.

Figura 7.

Ajuste del Modelo LSTM



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Tabla 5.

Medidas de desempeño del modelo LSTM

MAE	MSE	RMSE	R ²	RMSLE	MAPE
151.6707	44802.9788	202.5787	0.8684	0.1621	0.1208

Nota: Elaboración propia utilizando PyCaret en Google Colab.

El segundo modelo o método (LSTM), se elige porque como se demostró anteriormente tenía el mejor ajuste. No obstante, existen otros criterios que le favorecen en su elección. Es especialmente adecuado para series temporales debido a su capacidad para capturar dependencias

a largo plazo (Fiero, Castillo & Torres, 2022), con capacidad para modelar efectivamente las tendencias crecientes y los patrones estacionales que se observan en la serie, adaptándose a los cambios en la dinámica de la serie a lo largo del tiempo, como el aumento de la variabilidad después de 2016.

Ambos modelos seleccionados tienen la capacidad de manejar las características complejas de la serie temporal de la demanda de energía eléctrica en Santander como se describieron al final del apartado *Recolección de Datos Históricos*. Random Forest puede capturar relaciones no lineales y es robusto frente a outliers (Fiero, Castillo & Torres, 2022), mientras que LSTM es especialmente bueno para modelar dependencias temporales a largo plazo y adaptarse a cambios en la dinámica de la serie (Fiero, Castillo & Torres, 2022). Random Forest ofrecerá predicciones basadas en patrones complejos aprendidos de los datos históricos, mientras que LSTM podrá capturar y proyectar las tendencias y patrones secuenciales a lo largo del tiempo (Fiero, Castillo & Torres, 2022).

Es importante debatir la similitud de medidas de desempeño entre LSTM y Transformer, porque se podría pensar que por ello debería ser incluido este último como un modelo sugerido. Aunque el R^2 es muy similar entre ambos modelos (0.8684 versus 0.8605, respectivamente), LSTM consistentemente supera a Transformer en casi todas las métricas (excepto en MAPE, donde Transformer es ligeramente mejor). Pero existen otros criterios de selección que llevaron a no incluirla como sugerencia de pronóstico basándose en las sugerencias de Fierro, Castillo & Torres (2022):

- La serie temporal de la demanda de energía eléctrica en Santander tiene una tendencia clara y patrones estacionales, pero también muestra variaciones irregulares. LSTM es

particularmente eficaz para capturar dependencias a largo plazo en series temporales, lo que es crucial para este tipo de datos.

- Aunque los Transformers son muy potentes, tienden a requerir más datos y recursos computacionales para alcanzar su máximo rendimiento. Para esta serie temporal específica, que no parece tener una complejidad extrema, LSTM puede ofrecer un buen equilibrio entre rendimiento y eficiencia computacional.

- Los modelos LSTM, aunque son complejos, pueden ser más fáciles de interpretar y ajustar que los Transformers, especialmente para series temporales como esta.

- Los modelos LSTM tienen una historia más larga de aplicación exitosa en pronósticos de series temporales, lo que puede proporcionar más confianza en su estabilidad y rendimiento consistente.

- La serie muestra algunos outliers y cambios bruscos, especialmente después de 2016. Los LSTM han demostrado ser robustos en el manejo de tales anomalías en series temporales.


5.2.2 Implementación de Técnicas Seleccionadas como Favorables para el Pronóstico

De manera diferente a como se aplicaron los modelos en la sección anterior, donde se utilizaron, después de ser entrenados, para estimar los datos históricos desde el año 2000 al 2023, ahora, en esta sección se aplican los modelos Random Forest y LSTM para realizar predicciones o pronósticos de la demanda. Inicialmente se hace una evaluación del tipo de Rolling Horizon a utilizar bajo el escenario de pronóstico de la primera semana del 2024. Posteriormente, se hacen diferentes pronósticos con periodos de un año, un mes, y nuevamente de una semana para analizar el comportamiento predictivo de los modelos en estas diferentes ventanas temporales.

5.2.2.1 Pronóstico Bajo las Estrategias de Rolling Horizon Convencional y por Segmentación por Días, para Pronosticar la Demanda de la Primera Semana de Enero 2024

Se utilizaron, para comparación, dos metodologías de rolling horizon, la convencional y la de segmentación por días. La primera realiza un pronóstico con todos los datos históricos disponibles para pronosticar el periodo de interés (1 semana en este caso), y la segunda, divide los datos históricos disponibles de cada día, y los utiliza para predecir el valor de dicho día.

Figura 8.
Comparativa gráfica del pronóstico obtenido con la estrategia rolling horizon con segmentación por días



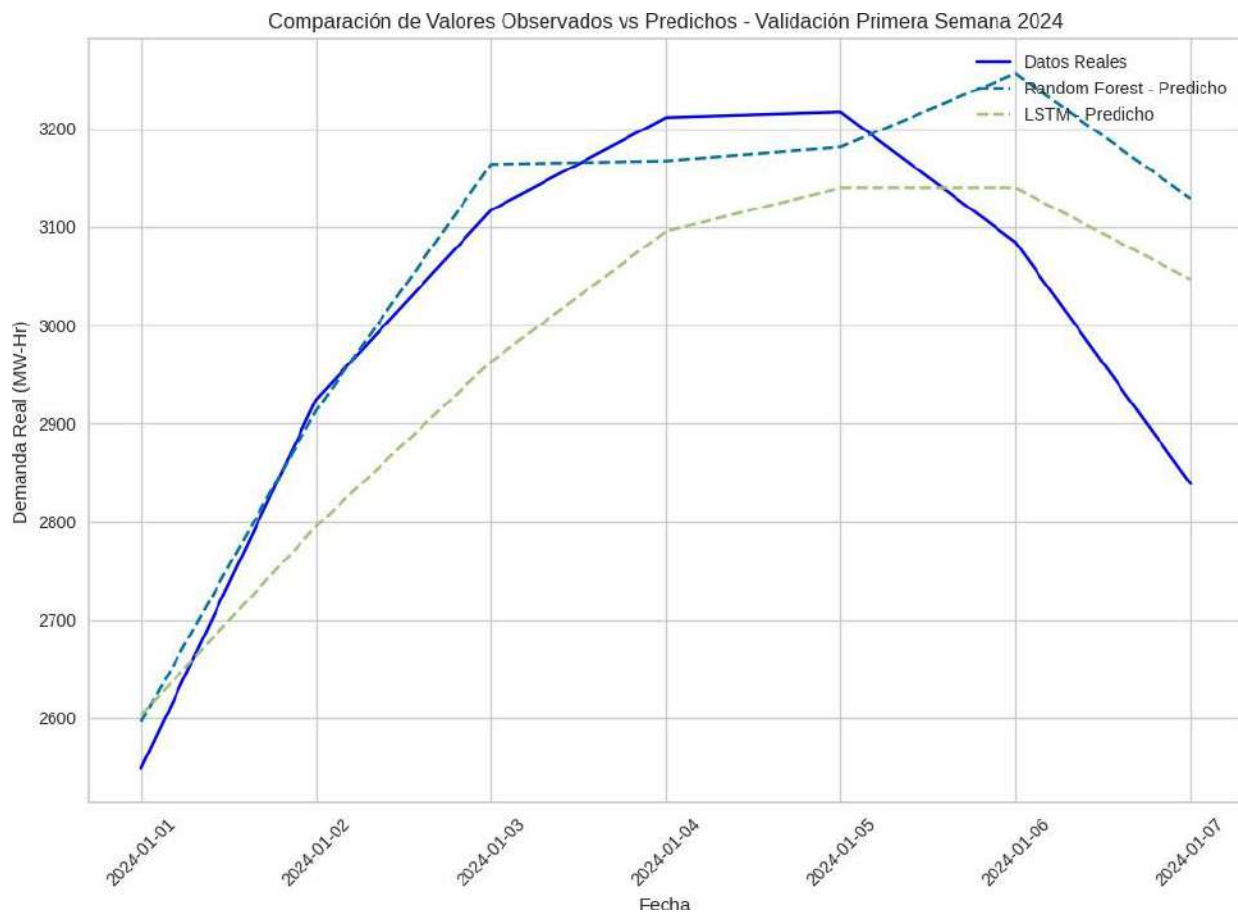
Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Al aplicar el pronóstico con la estrategia rolling horizon por segmentación por días, los valores comparados de cada método (Random Forest como línea de trazos cortos color verde y LSTM línea de trazos cortos en naranja) con los valores que realmente se generaron de demanda

en la primera semana de 2024 (línea continua de color azul), tal como se muestra en la siguiente figura, se puede observar que ambos pronósticos son fieles al movimiento aleatorio que presenta la demanda real, pero son muy distantes de estos valores.

Figura 9.

Comparativa gráfica del pronóstico obtenido con la estrategia rolling horizon convencional



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Ahora bien, al utilizar la estrategia del rolling horizon convencional, la figura 9 muestra que ambos métodos (línea de trazos cortos azules para Random Forest y línea de trazos cortos verdes para LSTM) tienden a seguir la dirección aleatoria de la demanda real con menor precisión

que como lo hace la estrategia del rolling horizon con segmentación, pero es más precisa en la estimación ya sus pronósticos son más cercanos a valores reales. También es importante notar, que la línea de Random Forest es con fácil lectura, más aproximada a los valores reales que la de LSTM. Otro patrón importante, es que ambas tienden a aumentar su distancia frente a los valores reales cuando pronostican los días sábado y domingo.

5.2.2.2 Evaluación del Desempeño de las Estrategias Rolling Horizon Analizadas para Pronosticar la Primera Semana de 2024

Se inicia este apartado de evaluación del desempeño, resumiendo en la tabla siguiente los valores reales de demanda para la primera semana del 2024 y los valores pronosticados por el CND.

Tabla 6.

Resumen de valores de demanda real y demanda pronosticada según el CND y los cuatro pronósticos generados en el proyecto para la primera semana del 2024

Fecha	Demanda Real	Pronostico CND	Estrategia de Rolling Horizon			
			Convencional		Segmentación por días	
			Pronostico RamdonForest	Pronostico LSTM	Pronostico RamdonForest	Pronostico LSTM
1/1/2024	2549.06771	2612.32762	2596.03388	2603.29586	2277.46479	3566.25658
1/2/2024	2924.24844	3096.99426	2912.8509	2795.13425	2423.42001	3762.35323
1/3/2024	3117.04942	3216.02462	3163.79904	2962.90565	2425.36902	3792.03184
1/4/2024	3211.29092	3244.59724	3167.16542	3095.56113	2454.96757	3751.73714
1/5/2024	3216.97144	3280.94311	3181.35729	3139.72211	2369.06645	3753.27148
1/6/2024	3084.39351	3220.01325	3256.07622	3139.72075	2271.26931	3582.03906
1/7/2024	2838.56985	2872.4495	3128.8833	3046.67684	1993.30971	3106.13209

Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos y los pronósticos del CND.

Tomando los valores anteriores, se utilizan aquí las medidas de desempeño que se emplearon en la fase anterior y que son propias del análisis de series de tiempo. La tabla siguiente resume los resultados de calcular estos indicadores. Para una mejor lectura, se generó una gráfica que se presenta en la figura subsiguiente, en donde se aprecian los valores traducidos visualmente en barras y que permiten comparar con mayor rapidez.

Tabla 7.

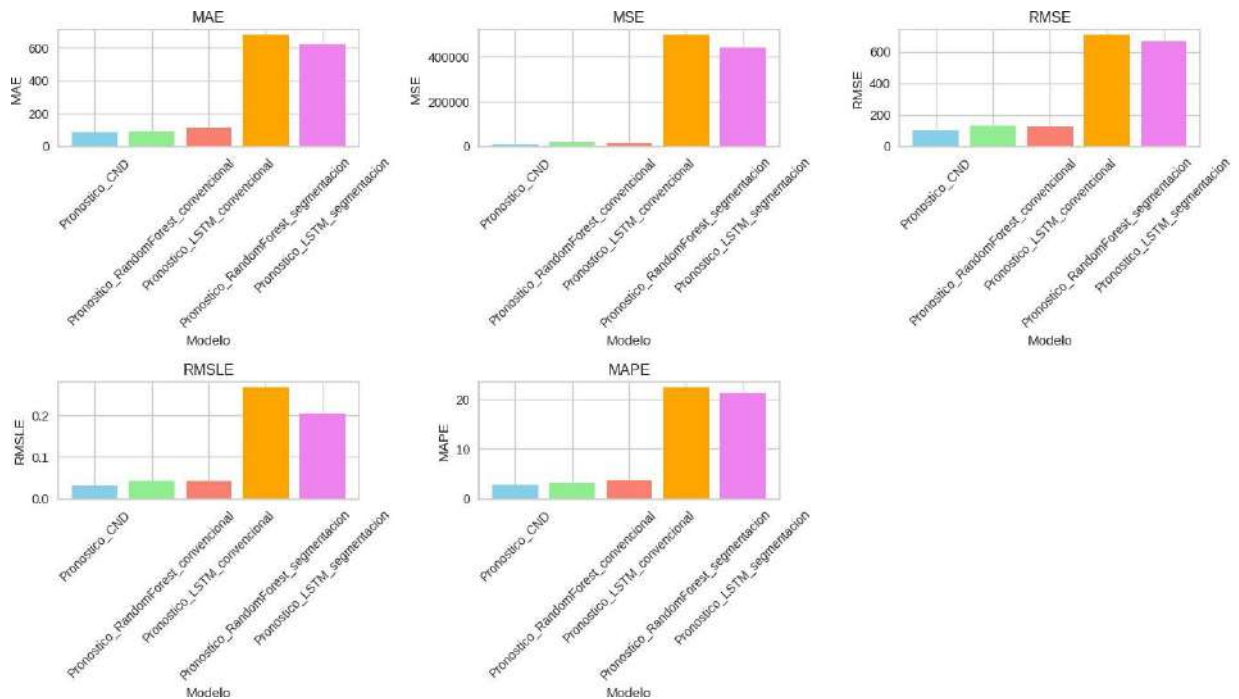
Comparación de Indicadores de Rendimiento entre Modelos para Predicción Primera Semana de 2024

Modelo	MAE	MSE	RMSE	RMSLE	MAPE
Pronostico CND	85.965.474	9.768.750.959	98.836.992	32.412	2.882.939
Pronostico RandomForest convencional	92.407.020	17.356.219.116	131.743.004	43.577	3.143.832
Pronostico LSTM segmentacion	624.604.305	441.662.087.465	664.576.623	204.575	21.325.740
Pronostico LSTM convencional	113.414.209	15.585.990.709	124.843.865	41.928	3.802.597
Pronostico RandomForest segmentacion	675.246.346	495.660.369.349	704.031.512	265.893	22.288.773

Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Figura 10.

Comparativa gráfica de los indicadores de rendimiento de los diferentes modelos Predicción Primera Semana 2024



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Se puede apreciar que la estrategia del rolling horizon con segmentación por días, genera barras y/o medidas de desempeño más altas para todas las medidas de desempeño, lo que permite concluir fácilmente y de manera técnica que la lectura visual de los valores que se hicieron en la Figura 8 son en realidad muy distantes de los valores reales.

En caso contrario, las barras y/o medidas de la estrategia del Rolling horizon convencional tiene valores menores, lo que es consecuente con lo observado en la Figura 9, donde los valores pronosticados no difieren drásticamente los valores reales.

Así, el rolling horizon convencional es mejor alternativa estratégica para el pronóstico utilizando Random Forest y LSTM. Queda por reconocer si estos métodos, utilizando la estrategia rolling horizon convencional son mejor alternativa que los métodos que utilizó el CND para su pronóstico en enero de este año (2024). Las barras y sus valores respectivos en las métricas de

desempeño, son muy cercanas entre CND y estos métodos, por lo que se decide compararlos bajo el indicador MAPE que es el que reconoce la CREG en su resolución 025 de 1995, solicitando que el pronóstico debe complacer un MAPE inferior o igual al 5%. Para realizar esta comparación se registra en la siguiente tabla, y figura, el MAPE para el pronóstico del CND y los métodos aquí valorados. Se aclara, que se consideró relevante calcular el MAPE, de manera adicional, para el pronóstico de los primeros cinco días de la semana, porque según la Figura 9, los métodos de este proyecto son más precisos para los primeros cinco días que para los dos últimos días.

La comparativa permite reconocer: i) que efectivamente los pronósticos con el rolling horizon con segmentación por días superan el MAPE permitido de hasta 5%; ii) En el pronóstico de la semana completa, los pronósticos con el Random Forest y LSTM bajo la estrategia rolling horizon convencional complacen el MAPE inferior del 5% solicitado por la CREG, con valores de 3.14% y 3.80% respectivamente, sin embargo, estos valores no superan el conseguido por el CND

Tabla 8.

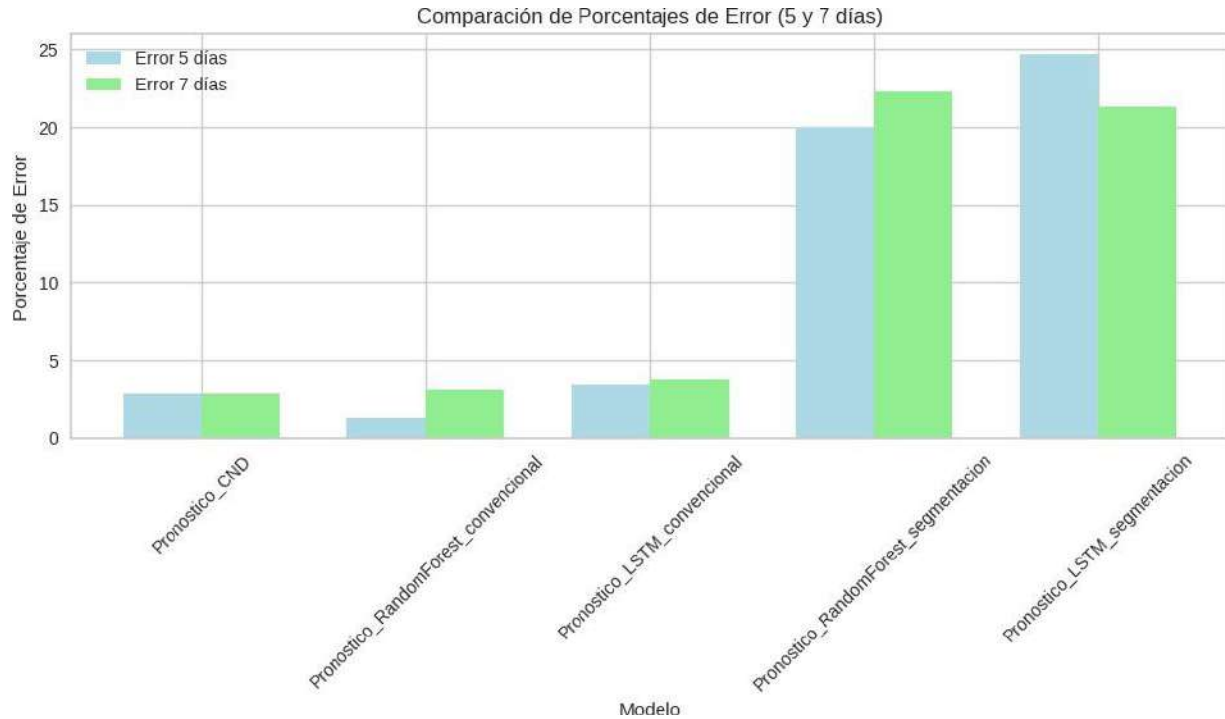
Resumen del indicador MAPE para el pronóstico de los primeros 5 días de la primera semana del 2024 y de dicha semana completa (7 días)

Modelo	Porcentaje de error promedio (7 días)	Porcentaje de error promedio (5 días)
Pronostico CND	2.88%	2.92%
Pronostico RandomForest convencional	3.14%	1.24%
Pronostico LSTM convencional	3.80%	3.50%
Pronostico RandomForest segmentacion	22.29%	19.98%
Pronostico LSTM segmentacion	21.33%	24.74%

Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Figura 11.

Comparativa gráfica del MAPE para los pronósticos de los primeros 5 días y los 7 días completos de la primera semana del 2024



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos de 2.88%; iii) no obstante, si solo se comparan los primeros cinco días de pronóstico (de lunes a viernes), el método Random Forest bajo la estrategia rolling horizon convencional obtiene un 1.24% de MAPE, haciéndolo superior en capacidad de pronóstico que el obtenido por el CND de 2.92% para este mismo rango de días, y superando con creces al LSTM convencional con 3.50%.

Los anteriores resultados muestran, como lo reconoce también Montoya (2021) en su interés por contribuir también a mejorar los pronósticos, que el CND debe y así lo hace, generar los pronósticos con una mezcla de diferentes técnicas. En este caso, podría utilizar el Random Forest para proponer el pronóstico de los días lunes a viernes, y continuar proponiendo el pronóstico del sábado y domingo con los métodos que hoy utiliza.

5.2.2.3 Análisis de los Pronósticos para Ventanas Temporales Anual, Mensual, y Semanal

Ahora, se evalúa el pronóstico de los modelos Random Forest y LSTM para tres ventanas temporales que siguen la descripción de planificación de mediano plazo (1 año) y corto plazo (1 semana), además que se agregó por interés propio el periodo de pronóstico de un mes.

Para el pronóstico de un (1) año, se hace comparando el pronóstico anual de los años 2019 a 2023, de manera separada cada año, y parte del año 2024 (8 meses disponibles de información de demanda real). La tabla siguiente presenta la comparación del error MAPE, utilizado por la UPME y exigido por la CREG para establecer el grado de precisión del modelo, en la figura siguiente se muestra el resultado del pronóstico para el año 2024, y en el Anexo A se comparten las gráficas de pronóstico para los años 2019 a 2023.

En primera instancia, se hace lectura de las gráficas, que incorporan, además, el intervalo de confianza al 95% de confianza:

- En cuanto al comportamiento del pronóstico, se observa capacidad para capturar los comportamientos globales de la demanda a lo largo del año, lo que es útil para pronósticos a largo plazo o para identificar tendencias de consumo generales. Sin embargo, la predicción del modelo muestra deficiencias para anticipar picos altos o bajos de demanda, lo que reduce su fiabilidad cuando se requieren predicciones más detalladas, especialmente en momentos donde la demanda presenta una alta variabilidad, como en los años de la pandemia (Véase años 2020 y 2021 de la Tabla 9).

Tabla 9.


MAPE obtenido al pronosticar un año de demanda con los modelos Random Forest y LSTM entre 2019 y 2024

	2019	2020	2021	2022	2023	2024 (8 meses)
Random Forest	9.41%	12.66%	15.32%	7.36%	8.19%	7.71%
LSTM	10.25%	11.33%	14.17%	7.22%	7.94%	7.08%

Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Figura 12.


Comparativo de datos reales versus pronosticados de lo corrido del año 2024 – Enero a Agosto (Random Forest)



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Figura 13.

Comparativo de datos reales versus pronosticados de lo corrido del año 2024 – Enero a Agosto (LSTM)



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

- Dado lo anterior, A pesar de que los intervalos de confianza incluyen las predicciones en la mayoría de los casos, no son lo suficientemente amplios como para abarcar los valores observados en varios periodos del año. Esto reduce su fiabilidad para proporcionar un rango seguro que permita una toma de decisiones basada en el riesgo.

- No obstante, los modelos captan con precisión los patrones generales y las tendencias estacionales de la demanda a lo largo del año, especialmente en los periodos más regulares. Así, el comportamiento de los modelos tiende a ser más conservadores, es decir, suavizan las predicciones en los periodos donde la demanda real muestra picos pronunciados. Esto se traduce en una subestimación de la demanda en los periodos de alto consumo y una sobreestimación en los periodos de bajo consumo. No obstante, es favorable que capturen los ciclos estacionales.

- Finalmente, es de advertir que el MAPE que proporcionan supera el límite esperado por la UPME y la CREG del 5%, con valores entre el 7% y 1% (Ver Tabla 9).

Lo anterior, sugiere el interés de comparar cómo evoluciona el MAPE cuando se pasa de pronósticos de un intervalo de tiempo a otro, como, por ejemplo, de una semana, a un mes, y a un año. Las siguientes dos tablas resumen el MAPE obtenido para dichas ventanas temporales en los años 2019 a 2024.

Tabla 10.

MAPE obtenido al pronosticar un mes de demanda (enero específicamente) con los modelos Random Forest y LSTM en los años 2018 y 2023

	2019	2020	2021	2022	2023	2024
Random Forest	7.12%	8.84%	11.01%	6.66%	6.48%	5.36%
LSTM	8.30%	9.67%	11.92%	7.03%	6.53%	6.13%

Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Tabla 11.

MAPE obtenido al pronosticar la primera semana de enero con los modelos Random Forest y LSTM en los años 2019 y 2024

	2019	2020	2021	2022	2023	2024
Random Forest	3.8%	5.8%	8.5%	7.7%	6.5%	3.1%
LSTM	4.80%	6.60%	8.80%	7.90%	6.7%	3.80%

Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos


Para un mejor análisis de las tablas anteriores, se presenta una comparativa visual en las siguientes figuras. La primera compara los pronósticos a intervalos diferentes, anual, mensual, semanal, para el modelo Random Forest, y la segunda para el modelo LSTM. Esta comparativa permite entender lo siguiente:

- De las tablas se puede entender que el modelo LSTM en general siempre da un MAPE mayor al que entrega Random Forest. Pronósticos para un año o un mes, superan siempre el límite esperado del 5% de error. En el caso semanal, se consiguen pronósticos inferiores al 5% pero solo en el año 2019 y 2024, por lo que se puede considerar el efecto de la pandemia como drástica Influencia sobre la capacidad de los modelos para detectar las variaciones imprevistas.

- De las figuras, es claro que, a menor tiempo de pronóstico, como una semana, por ejemplo, menores son los errores.

Figura 14.

Comparativo del MAPE obtenido para ventas temporales anual, mensual, semanal con Random Forest




Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Nota: El pronóstico mensual obedece a enero de cada año, y el semanal a la primera semana de cada año.

Figura 15.

Comparativo del MAPE obtenido para ventas temporales anual, mensual, semanal con LSTM



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Nota: El pronóstico mensual obedece a enero de cada año, y el semanal a la primera semana de cada año.

6. Conclusiones

Este trabajo de grado ha analizado el rendimiento de los pronósticos de demanda de energía eléctrica en Santander utilizando técnicas avanzadas de inteligencia artificial. A través de un análisis exhaustivo y la aplicación de diversos modelos predictivos, Random Forest y LSTM en específico, se han alcanzado importantes conclusiones sobre la eficacia y el desempeño de estos modelos en la predicción de la demanda energética.

El primer objetivo específico de la investigación fue la recolección de datos históricos de demanda de energía en Santander, de los cuales se obtuvo información de demanda real para el periodo diario en MW-Hr comprendido entre el 01-enero-2000 y el 20-ago-2024. Los otros dos objetivos específicos identifican una técnica de pronóstico de mejor ajuste diferente a Random Forest para usar como técnica patrón de comparación, y evalúan los rendimientos tanto de estimación como de pronóstico. Los siguientes apartados concluyen sobre estos aspectos.

6.1 Elección de la técnica LSTM como mejor ajuste.

En el análisis preliminar para encontrar una técnica de mejor ajuste, se incluyeron cuatro técnicas de estimación basadas en inteligencia artificial, diferentes el Random Forest, de donde, comparándolas con Random Forest se encontró que, en definitiva, Random Forest fue el modelo con mejor desempeño general, seguido de cerca por el LSTM. Al respecto, el primero obtuvo un coeficiente de determinación (capacidad para capturar o explicar la variabilidad de los datos), $R^2 = 0.88$, y el segundo $R^2 = 0.87$.

6.2 Implementación y Evaluación de los Modelos Para Realizar Pronósticos

En la fase de implementación, se aplicaron los modelos Random Forest y LSTM en la siguiente secuencia de evaluación: 1) inicialmente se analiza cuál estrategia es más pertinente para el pronóstico, si utilizar un entrenamiento con Rolling Horizon convencional o por segmentación

por días; 2) posteriormente se realizan los pronósticos para las ventanas temporales anual, mensual y semanal.

Sobre la evaluación del Rolling Horizon, se utiliza la predicción de la demanda de energía durante la primera semana de enero de 2024. Se utilizaron dos metodologías de Rolling Horizon: la convencional y la de segmentación por días. Los resultados indicaron que el Random Forest bajo la estrategia de Rolling Horizon convencional ofreció la mayor precisión en las predicciones, con un MAPE (Error Porcentual Absoluto Medio) de 3.14% para la semana completa y 1.24% para los primeros cinco días. Estos resultados superaron al pronóstico del CND, que presentó un MAPE de 2.88% para la semana completa.

En definitiva, la estrategia de Rolling Horizon convencional se demostró más efectiva que la de segmentación por días en términos de precisión. Los pronósticos generados con la estrategia de segmentación por días mostraron errores más altos y distancias mayores respecto a los valores reales, indicando que esta metodología puede no ser la más adecuada para esta serie temporal en particular.

Teniendo la claridad que debía preferirse el Rolling Horizon convencional, se procedió a evaluar la precisión de los pronósticos para la ventana temporal anual, mensual y semanal, tomando los años 2019 a 2024 (en este último solo los meses de enero a agosto), en el mensual, el mes de enero de cada año, y en el semanal, la primera semana de cada año.

Los resultados del MAPE para las ventanas temporales anuales y mensuales no logran alcanzar el tope máximo de error permitido por la UPME y el CND del 5%. Tomando valores en lo anual entre 7% y 15% de error, y en lo mensual entre 5% y 11%. Esto sugiere, no solamente la incapacidad del pronóstico anual y mensual de ser útil para la UPME y CREG, según sus criterios

de confiabilidad de pronósticos, sino también que, a mayor tiempo de pronóstico, el error crece también.

Ahora bien, dado que, en la ventana temporal de una semana en el 2024, los resultados eran más prometedores, al comparar este escenario en todos los demás años, se concluye que, en dicha ventana, aunque se logran errores inferiores al 5% en los años 2019 y 2024, en los demás años se supera este límite. La explicación más plausible sobre esta diferencia, radicaría en que la pandemia inició en el año 2020 y aunque terminó en el 2022, para los modelos, su incidencia no fue detectable rápidamente y además perdura en el pronóstico un tiempo adicional. Esto se concluye porque los errores crecen en 2020 y 2021 y luego comienzan a decrecer, hasta lograr en el 2024 nuevamente los niveles esperados inferiores al 5%.

Finalmente, se puede decir, que los modelos de inteligencia artificial, aunque más precisos que otros modelos como lo afirman diferentes autores, se basan en información histórica y que no tienen la capacidad de predecir eventualidades como en este caso la de una pandemia, y, por ende, el CND utiliza métodos híbridos para sus pronósticos, siendo el Random Forest una buena consideración, aunque no única, como se ha demostrado en este proyecto.

6.3 Evaluación del Desempeño de los Modelos

La aplicación de técnicas de evaluación de desempeño de modelos ha demostrado que el Random Forest es el modelo más robusto para la predicción de la demanda. Este modelo ha destacado en diversas métricas de precisión. En particular, el Error Absoluto Medio (MAE) del Random Forest fue de 123.50, indicando que, en promedio, las predicciones de este modelo se desvían solo 123.50 unidades de los valores reales. Este bajo MAE es indicativo de su capacidad para realizar estimaciones precisas.

El Error Cuadrático Medio (MSE) del Random Forest fue de 30,996.66, lo que muestra que el modelo penaliza menos los errores grandes en comparación con otros modelos, como el SVM que presentó un MSE de 337,892.02. El Raíz del Error Cuadrático Medio (RMSE) del Random Forest fue de 168.52, confirmando su rendimiento sobresaliente en términos de precisión general. Además, el Coeficiente de Determinación (R^2) del Random Forest fue de 0.88, indicando que el modelo explica el 88.32% de la variabilidad en los datos de demanda. Este alto valor de R^2 sugiere un ajuste muy bueno a los datos históricos y una capacidad superior para capturar las tendencias y patrones presentes en la serie temporal de demanda.

Por otro lado, el modelo LSTM también mostró un rendimiento destacado, aunque no tan superior como el Random Forest en todas las métricas. El MAE del LSTM fue de 151.67 y el RMSE fue de 202.58. Su R^2 de 0.87 indica que el modelo explica el 87% de la variabilidad en los datos, lo que es muy cercano al valor obtenido con el Random Forest.

7. Recomendaciones

Los hallazgos de esta investigación sugieren que la combinación de Random Forest y LSTM puede ofrecer una solución robusta para mejorar las predicciones de demanda de energía. Se recomienda utilizar Random Forest para los días de semana, dada su capacidad para manejar relaciones no lineales y su bajo MAPE, mientras que LSTM puede ser aplicado para capturar patrones estacionales y tendencias a largo plazo, complementando así el rendimiento del Random Forest.

Además, se sugiere que el CND considere la integración de estos modelos avanzados en su sistema de pronóstico para mejorar la precisión y la fiabilidad de las estimaciones de demanda. La combinación de técnicas y el uso de modelos complementarios pueden resultar en pronósticos más precisos y útiles para la planificación y gestión de la demanda energética en Santander.

Referencias Bibliográficas

- Aggarwal, S. K., Saini, L. M., & Kumar, A. (2009). Short-term electricity price forecasting in deregulated markets: A review of statistical models and key issues. *International Journal of Energy Sector Management*, 3(4), 333–358. doi: 10.1108/17506220911005731.
- Alí, M. (2020). PyCaret: An open source, low-code machine learning library in Python.
- PyCaret. <https://pycaret.org>
- Ansarin, M., Ketter, W., & Collins, J. (2016). Analysis and improvement of the balancing market in electricity retail competition. In *IEEE PES Innovative Smart Grid Technologies Conference Europe* (pp. 1–6). doi: 10.1109/ISGTEurope.2016.7856197.
- Antoniadis, A., Lambert-Lacroix, S., & Poggi, J. M. (2021). Random forests for global sensitivity analysis: A selective review. *Reliability Engineering & System Safety*, 206, 107312.
- Bisoi, R., Dash, P. K., & Das, P. P. (2020). Short-term electricity price prediction and classification in smart grids using an optimized multikernel extreme learning machine. *Neural Computing and Applications*, 32(5), 1457–1480. doi: 10.1007/s00521-018-3652-5.
- Bottieau, J., Hubert, L., De Grève, Z., Vallée, F., & Toubeau, J. F. (2020). Probabilistic very short-term forecasting for risk-aware participation in single-price imbalance settlement. *IEEE Transactions on Power Systems*, 35(2), 1218–1230. doi: 10.1109/TPWRS.2019.2940756.
- Cai, Z., et al. (2015). Application of battery energy storage for wind power generation forecasting errors compensation in 2050. *Energy Procedia*, 73, 208–217. doi: 10.1016/j.egypro.2015.07.673.
- Chen, T., Guestrin, C., & Wang, X. (2023). AutoML: A survey of the state-of-the-art. *ACM Computing Surveys*, 55(6), 1-37.

- Croonenbroeck, C., & Stadtmann, G. (2019). Estudios de previsión de generación renovable: revisión y orientación sobre buenas prácticas. *Renewable and Sustainable Energy Reviews*, 108(April), 312–322. doi: 10.1016/j.rser.2019.03.029.
- Cui, T., Wang, Y., Goudarzi, H., Nazarian, S., & Pedram, M. (2012). Profit maximization for utilities in an oligopolistic energy market with dynamic pricing. In *2012 IEEE Online Green Communications Conference (GreenCom 2012)* (Vol. 4, December 2015, pp. 86–91). doi: 10.1109/GreenCom.2012.6519621.
- Cuisinier, É., Lemaire, P., Penz, B., Ruby, A., & Bourasseau, C. (2022). New rolling horizon optimization approaches to balance short-term and long-term decisions: An application to energy planning. *Energy*, 245, 122773.
- De Weerd, M., Ketter, W., & Collins, J. (2021). Pricing mechanism for real-time balance in regional electricity markets. In *Belgian/Dutch Artificial Intelligence Conference, 2021*.
- Essl, A., Ortner, A., Haas, R., & Hettegger, P. (2017). Machine learning analysis for a flexible energy approach towards integrating renewables with dynamic electricity balance forecasting. In *International Conference on European Energy Market (EEM, July 2017)*. doi: 10.1109/EEM.2017.7981877.
- EURELECTRIC. (2017). *Dynamic Pricing in Electricity Supply*, February, 16.
- Fierro Torres, C. Á., Castillo Pérez, V. H., & Torres Saucedo, C. I. (2022). Análisis comparativo de modelos tradicionales y modernos para pronóstico de la demanda: enfoques y características. *RIDE. Revista Iberoamericana para la Investigación y el Desarrollo Educativo*, 12(24).
- Georgilakis, P. S. (2022). Artificial intelligence solution to the electricity price forecasting problem. *Applied Artificial Intelligence*, 21(8), 707–727. doi: 10.1080/08839510701526533.

- Géron, A. (2022). Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems (3rd ed.). O'Reilly Media.
- Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. *Neural Computation*, 12(10), 2451-2471.
- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2017). LSTM: A search space odyssey. *IEEE Transactions on Neural Networks and Learning Systems*, 28(10), 2222-2232.
- Grimaldo G., J. W. (2012). Modelo de predicción de la demanda de energía eléctrica en Santander por regresiones múltiples. Ingeniería Eléctrica. Trabajo de grado de Pregrado. Universidad del Norte.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.
- Hurtado, S. M., & Aguado, J. G. (2005). Predicción de demanda de energía en Santander mediante un sistema de inferencia difuso neuronal. *Energética*, (33), 15-24.
- Inman, R. H., Pedro, H. T. C., & Coimbra, C. F. M. (2013). Métodos de previsión solar para la integración de energías renovables. *Progress in Energy and Combustion Science*, 39(6), 535–576. doi: 10.1016/j.pecs.2013.06.002.
- Jaehnert, S., Farahmand, H., & Doorman, G. L. (2019). Price modeling using volume in the Norwegian regulator energy market. In *IEEE Bucharest PowerTech Innovative Ideas for the Electric Power Industry Future* (pp. 1–7). doi: 10.1109/PTC.2009.5281972.
- Kok, K., et al. (2018). Electricity balance based on agent with distributed energy resources, a multiple-perspective case study. In *Proceedings of the Annual Hawaii International Conference on System Sciences, 2018*. doi: 10.1109/HICSS.2008.46.

- Kumar, A. (2022). Automated feature engineering techniques for machine learning. *Journal of Machine Learning Research*, 23(1), 1-45.
- Lim, B., Arık, S. Ö., Loeff, N., & Pfister, T. (2021). Temporal fusion transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*, 37(4), 1748-1764.
- Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30, 4765-4774.
- Luo, B., & Miao, S. (2019). A Literature Survey on Electricity Price Forecasting in Deregulated Markets. In *iSPEC 2019 - 2019 IEEE Sustainable Power and Energy Conference: Grid Modernization for Energy Revolution* (pp. 359–365). doi: 10.1109/iSPEC48194.2019.8974939.
- Moez, A. (2021). PyCaret: An open source, low-code machine learning library in Python. *Journal of Open Source Software*, 6(64), 3210.
- Montoya Cardona, J. F. (2021). *Pronóstico de la demanda de energía en Colombia a corto plazo basado en un modelo híbrido adaptativo* (Doctoral dissertation, Universidad Nacional de Colombia).
- Murillo, J., Trejos, A., & Olaya, P. C. (2003). Estudio del pronóstico de la demanda de energía eléctrica, utilizando modelos de series de tiempo. *Scientia et Technica*, 3(23).
- Negnevitsky, M., Mandal, P., & Srivastava, A. K. (2009). Machine learning applications for load, price, and wind power prediction in power systems. In *2009 15th International Conference on Intelligent System Applications to Power Systems (ISAP '09)* (pp. 1–6). doi: 10.1109/ISAP.2009.5352820.


- Olsson, M., & Söder, L. (2008). Real-time balancing market electricity price modeling using combined SARIMA and Markov processes. *IEEE Transactions on Power Systems*, 23(2), 443–450. doi: 10.1109/TPWRS.2008.920046.
- Pascanu, R., Mikolov, T., & Bengio, Y. (2013). On the difficulty of training recurrent neural networks. In *Proceedings of the 30th International Conference on Machine Learning* (pp. 1310-1318).
- Razak, et al. (2021). Support vector machine for next day electricity price forecasting. In *AIP Conference Proceedings* (Vol. 1660). doi: 10.1063/1.4915865.
- Rueda, V., Velásquez H., J. D., & Franco C., C. J. (2011). Avances recientes en la predicción de la demanda de electricidad usando modelos no lineales. *Dyna*, 78(167), 36-43.
- Santos, G., Pinto, T., Vale, Z., Morais, H., & Praca, I. (2022). Market integration balance in the MASCEM electricity market simulator. In *IEEE Power & Energy Society General Meeting* (pp. 1–8). doi: 10.1109/PESGM45291.2022.9668953.
- Sarmiento, H., & Villa, W. (2008). Inteligencia artificial en pronóstico de demanda de energía eléctrica: una aplicación en optimización de recursos energéticos. *Revista Santanderna de Tecnologías Avanzadas*, 2(12), 94-100.
- Siami-Namini, S., Tavakoli, N., & Namin, A. S. (2019). A comparative analysis of forecasting financial time series using ARIMA, LSTM, and BiLSTM. arXiv preprint arXiv:1911.09512.
- Vasirani, M., & Ossowski, S. (2023). Smart load balancing: State of the art and empirical evaluation in the Spanish electricity market. *Artificial Intelligence Review*, 39(1), 81–95. doi: 10.1007/s10462-012-9391-6.

Wang, Q., Li, F., Tang, Y., & Xu, Y. (2019). Integration of model-based and data-driven methods for power system frequency stability assessment and control. *IEEE Transactions on Power Systems*, 34(6), 4557–4568. doi: 10.1109/TPWRS.2019.2919522.

Anexo A. Gráficas de Predicción de la Demanda Anuales para los Años 2019 a 2024

Figura 16.


Comparativo de datos reales versus pronosticados para el año 2019 (Random Forest)



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Figura 17.


Comparativo de datos reales versus pronosticados para el año 2019 (LSTM)



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Figura 18.


Comparativo de datos reales versus pronosticados para el año 2020 (Random Forest)



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Figura 19.


Comparativo de datos reales versus pronosticados para el año 2020 (LSTM)



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Figura 20.


Comparativo de datos reales versus pronosticados para el año 2021 (Random Forest)



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Figura 21.


Comparativo de datos reales versus pronosticados para el año 2021 (LSTM)



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Figura 22.


Comparativo de datos reales versus pronosticados para el año 2022 (Random Forest)



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Figura 23.

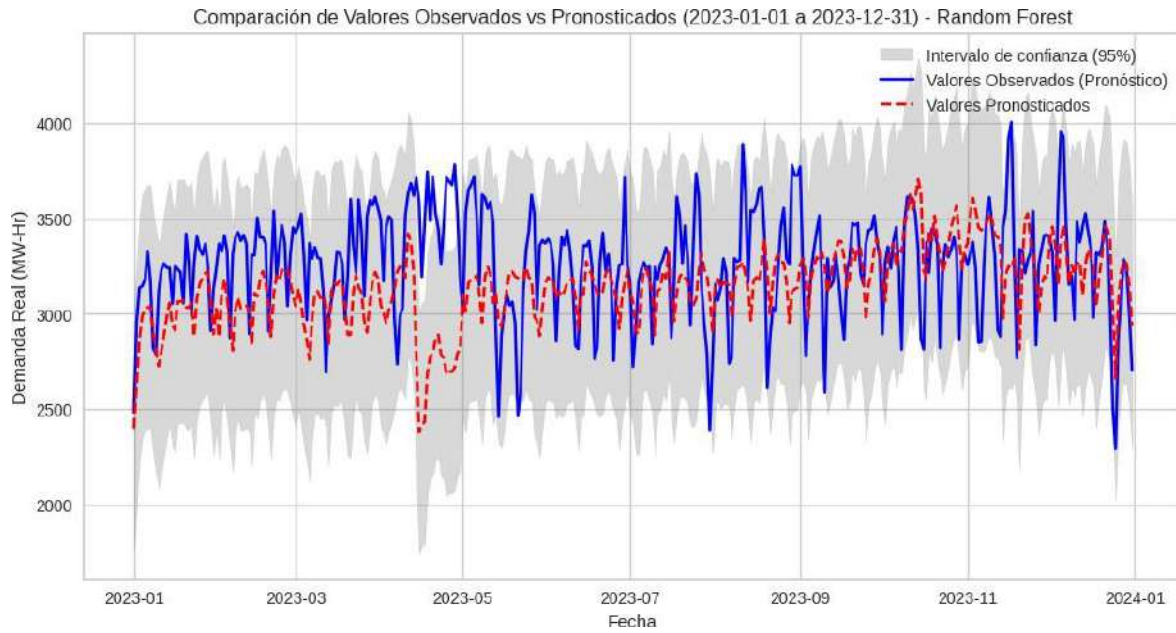
Comparativo de datos reales versus pronosticados para el año 2022 (LSTM)



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Figura 24.

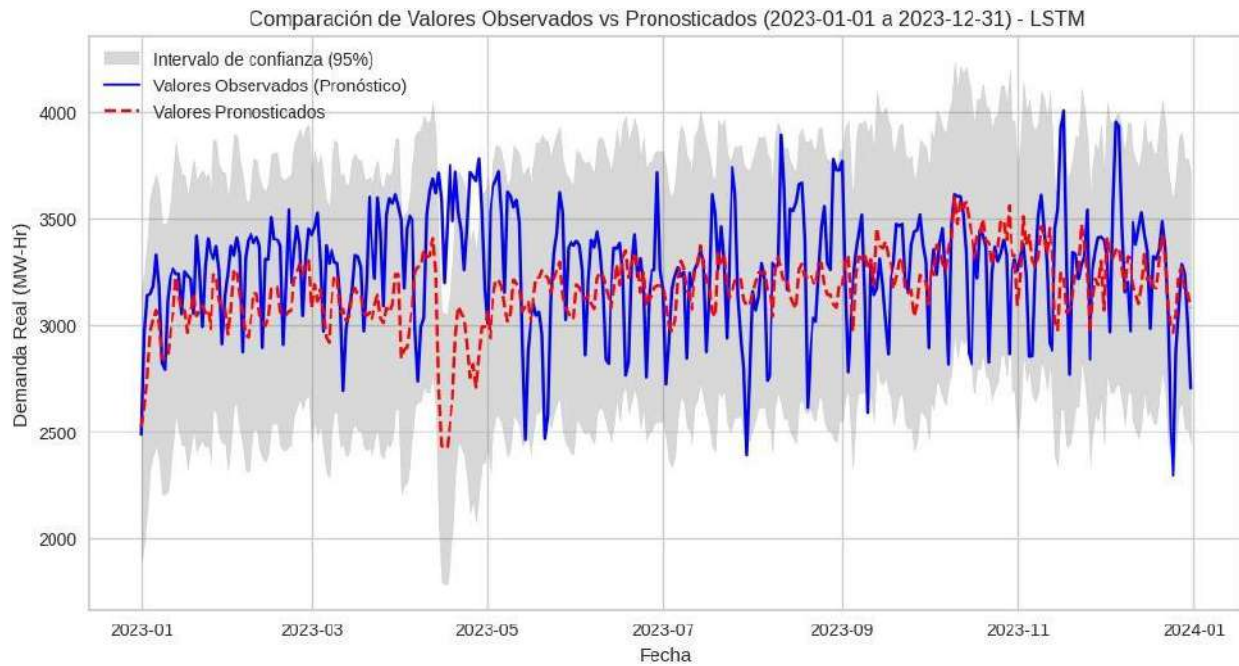
Comparativo de datos reales versus pronosticados para el año 2023 (Random Forest)



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos

Figura 25.

Comparativo de datos reales versus pronosticados para el año 2023 (LSTM)



Fuente: obtenido al aplicar comandos de Pycaret en Google Colab a los datos