

**Modelos de predicción de la demanda eléctrica y detección de picos de consumo  
mediante series de tiempo y Machine Learning**

Juan Pablo Muñoz Carmona

Asesor

Bryan Andru Montenegro Embus

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

2026

## **Agradecimientos**

A mi mamá por siempre ser la mayor fuente de apoyo, a mis compañeros y amigos por estar presentes en cada momento de aprendizaje. Y a la vida por tantas oportunidades para seguir aprendiendo y creciendo personal y académicamente.

## Resumen

La proyección de la demanda eléctrica es un desafío global que requiere herramientas avanzadas para reducir la incertidumbre generada por la variabilidad climática y otras condiciones socioeconómicas de cada región. Colombia se enfrenta a retos específicos asociados al crecimiento de la población y la alta dependencia de generación hidroeléctrica, lo cual hace indispensable el desarrollo e implementación de metodologías robustas de estimación de la demanda. En consecuencia, se implementó un proceso de evaluación de dos modelos de series de tiempo y Machine Learning para estimar la demanda de energía eléctrica en Colombia en resoluciones diaria y mensual a partir de datos entre enero de 2015 y diciembre de 2025 y generar pronósticos para el horizonte 2026-2029 con base en la metodología CRISP-DM. Se realizó un análisis exploratorio de datos para comprender la dinámica temporal y la asociación estadística de la demanda eléctrica y los aportes hidrológicos, el volumen de los embalses, el Producto Interno Bruto (PIB) y el crecimiento de la población. A pesar de la fuerte relación entre la población y la demanda eléctrica, se realizó el modelado sin esta ni el PIB debido a su resolución temporal (anual y trimestral, respectivamente).

En el modelado se realizó la comparación del enfoque univariado (solo demanda) y un enfoque multivariado (demanda, aportes hidrológicos, volumen de embalses). Fueron implementadas dos arquitecturas: 1) modelo híbrido con series de tiempo y Machine Learning y 2) modelo aditivo generalizado basado en series de tiempo, Prophet. Las métricas para evaluar el desempeño predictivo fueron la raíz del error cuadrático medio (RMSE), el promedio del error absoluto porcentual (MAPE) y el promedio del error escalado absoluto (MASE). La información fue recopilada de XM, el DANE y la UPME. Tras la búsqueda de los hiperparámetros óptimos para cada configuración, el modelo campeón fue el híbrido univariado mensual. El Pipeline para

garantizar la reproducibilidad de los resultados de la investigación fue consignado en 4 scripts de Python. En términos generales se evidenció que el enfoque univariado tuvo mejores resultados en todos los procesos de modelado. Las estimaciones del modelo campeón fueron comparadas con proyecciones oficiales de la UPME y el MAPE fue de 2.4%.

***Palabras clave:*** demanda eléctrica, series de tiempo, machine learning, Prophet, ciencia de datos

## Abstract

The projection of electricity demand is a global challenge that requires advanced tools to reduce the uncertainty generated by climate variability and other socioeconomic conditions in each region. Colombia faces specific challenges associated with population growth and high dependence on hydroelectric generation, which makes the development and implementation of robust demand estimation methodologies indispensable. Consequently, an evaluation process of two time series and Machine Learning models was implemented to estimate the demand for electricity in Colombia in daily and monthly resolutions based on data between January 2015 and December 2025 and generate forecasts for the 2026-2029 horizon based on the CRISP-DM methodology. An exploratory data analysis was performed to understand the temporal dynamics and statistical association of electricity demand and hydrological inputs, reservoir volume, Gross Domestic Product (GDP), and population growth. Despite the strong relationship between population and electricity demand, the modelling was carried out without electricity demand or GDP due to its temporal resolution (annual and quarterly, respectively).

In the modeling, the univariate approach (demand only) and a multivariate approach (demand, hydrological inputs, reservoir volume) were compared. Two architectures were implemented: 1) hybrid model with time series and Machine Learning and 2) generalized additive model based on time series, Prophet. The metrics to evaluate predictive performance were Root Mean Square Error (RMSE), Mean Percent Absolute Error (MAPE), and Mean Absolute Scaled Error (MASE). The information was collected from XM, DANE and UPME. After the search for the optimal hyperparameters for each configuration, the champion model was the monthly univariate hybrid. The Pipeline to guarantee the reproducibility of the research results was consigned to four Python scripts. In general terms, it was evidenced that the

univariate approach had better results in all modeling processes. The estimates of the champion model were compared with official projections of the UPME and the MAPE was 2.4%.

***Key words:*** electricity demand, time series, machine learning, Prophet, data science

## Tabla de Contenido

Introducción .....	14
Planteamiento del Problema .....	15
Justificación .....	17
Objetivos .....	19
Objetivo General.....	19
Objetivos Específicos .....	19
Estado del Arte.....	20
Machine Learning en la Demanda Eléctrica.....	20
Modelos Aditivos en la Demanda Eléctrica .....	21
Univariado vs Multivariado.....	22
Vacío de Conocimiento .....	23
Marco Teórico.....	25
Electricidad .....	25
Sistema Interconectado Nacional .....	26
Crecimiento Poblacional en Colombia .....	27
Series de Tiempo .....	28
Prophet.....	31
Inteligencia Artificial.....	33
Pipelines Analíticos .....	38
Metodología .....	40
Enfoque Metodológico .....	40
Fase 1 Identificación y Preparación de los Datos.....	40

Entendimiento del Problema y Obtención de Datos .....	40
Análisis Exploratorio y Preparación de los Datos .....	43
Fase 2 Comparación y Experimentación de Modelos .....	45
Arquitectura del Modelo Híbrido .....	45
Optimización de Hiperparámetros y Validación Cruzada .....	46
Evaluación, Intervalos de Predicción y Extrapolación .....	48
Fase 3 Diseño de la Solución y Encapsulamiento .....	49
Arquitectura del Pipeline de Datos .....	49
Estrategia del Encapsulamiento .....	50
Consideraciones de Uso, Limitaciones y Mantenimiento .....	50
Resultados .....	52
Análisis Exploratorio de Datos (EDA) .....	52
Demanda de Energía Eléctrica.....	52
Estacionalidad Horaria y Semanal.....	52
Dinámica Mensual y Efectos Estacionales .....	53
Análisis Cuantitativo de la Demanda .....	53
Población Nacional .....	55
Dinámica de Crecimiento Interanual a Corto Plazo .....	56
Producto Interno Bruto (PIB) .....	57
Dinámica Trimestral Histórica .....	58
Análisis Comparativo Frente al Promedio Histórico.....	59
Aportes Hidrológicos y Embalses Nacionales.....	59
Estacionalidad Hidrológica Interanual y Caso Atípico de 2025.....	60

Dinámica del Volumen de los Embalses .....	62
Análisis de Correlación Cruzada .....	64
Evaluación y Comparación de Modelos .....	69
Modelación Diaria Univariada .....	69
Modelación Diaria Multivariada.....	72
Limitación de la Extrapolación Multivariada .....	75
Modelación Mensual Univariada.....	75
Modelación Mensual Multivariada.....	79
Selección del Modelo Óptimo .....	82
Validación Frente a Proyecciones Oficiales (UPME) .....	83
Consolidación del Pipeline .....	85
Conclusiones .....	86
Recomendaciones .....	88
Referencias Bibliográficas .....	89
Apéndices.....	104

## Lista de Tablas

<b>Tabla 1</b> <i>Variables Obtenidas de XM</i> .....	41
<b>Tabla 2</b> <i>Datos Obtenidos del DANE</i> .....	42
<b>Tabla 3</b> <i>Datos Obtenidos de la UPME</i> .....	43
<b>Tabla 4</b> <i>Interpretación del Coeficiente de Correlación</i> .....	44
<b>Tabla 5</b> <i>Parámetros y Rangos Usados en la Validación de Hiperparámetros de Elastic Net</i> ....	46
<b>Tabla 6</b> <i>Parámetros y Rangos Usados en la Validación de Hiperparámetros de XGB</i> .....	47
<b>Tabla 7</b> <i>Parámetros y Rangos Usados en la Validación de Hiperparámetros de Prophet</i> .....	48
<b>Tabla 8</b> <i>Estadísticas Descriptivas de la Demanda Eléctrica Desglosadas por Año</i> .....	54

## Lista de Figuras

<b>Figura 1</b> <i>Esquema de Modelación de la Demanda</i> .....	48
<b>Figura 2</b> <i>Demanda de Energía Eléctrica en Colombia en Múltiples Escalas – 2015 a 2025</i> .....	52
<b>Figura 3</b> <i>Cambio Porcentual Anual de la Demanda Eléctrica</i> .....	55
<b>Figura 4</b> <i>Población Actual y Proyectada hasta 2070</i> .....	56
<b>Figura 5</b> <i>Cambio Porcentual Anual de la Población</i> .....	57
<b>Figura 6</b> <i>Variación Trimestral del PIB Total y del Sector Eléctrico</i> .....	58
<b>Figura 7</b> <i>Variación del PIB Trimestral Año a Año</i> .....	58
<b>Figura 8</b> <i>Cambio Porcentual Trimestral del PIB</i> .....	59
<b>Figura 9</b> <i>Aportes Hidrológicos vs ONI</i> .....	60
<b>Figura 10</b> <i>Aportes Hidrológicos Mensuales por Año</i> .....	61
<b>Figura 11</b> <i>Aportes Hidrológicos de 2025 vs Promedio Histórico</i> .....	61
<b>Figura 12</b> <i>Volumen Promedio de los Embalses vs ONI</i> .....	62
<b>Figura 13</b> <i>Volumen Promedio de los Embalses por Año</i> .....	63
<b>Figura 14</b> <i>Volumen Promedio de los Embalses en 2025 vs Promedio Histórico</i> .....	63
<b>Figura 15</b> <i>Correlación entre Demanda, Aportes y Volumen en Escala Diaria</i> .....	64
<b>Figura 16</b> <i>Correlación entre Demanda, Aportes y Volumen en Escala Mensual</i> .....	65
<b>Figura 17</b> <i>Correlación entre Demanda, Aportes, Volumen y PIB en Escala Trimestral</i> .....	66
<b>Figura 18</b> <i>Correlación entre Demanda, Aportes, Volumen, PIB y Población en Escala Anual</i> .	67
<b>Figura 19</b> <i>Análisis Multivariado en Escala Anual</i> .....	68
<b>Figura 20</b> <i>Proyección de la Demanda Eléctrica Diaria Univariada con Modelo Híbrido</i> .....	70
<b>Figura 21</b> <i>Validación Demanda Eléctrica Diaria Univariada con Modelo Híbrido 2025</i> .....	70
<b>Figura 22</b> <i>Proyección de la Demanda Eléctrica Diaria Univariada con Modelo Prophet</i> .....	71

<b>Figura 23</b> <i>Validación Demanda Eléctrica Diaria Univariada con Prophet 2025</i> .....	72
<b>Figura 24</b> <i>Proyección de la Demanda Eléctrica Diaria Multivariada con Modelo Híbrido</i> .....	73
<b>Figura 25</b> <i>Validación Demanda Eléctrica Diaria Multivariada con Modelo Híbrido 2025</i> .....	73
<b>Figura 26</b> <i>Proyección de la Demanda Eléctrica Diaria Multivariada con Prophet</i> .....	74
<b>Figura 27</b> <i>Validación Demanda Eléctrica Diaria Multivariada con Prophet 2025</i> .....	75
<b>Figura 28</b> <i>Proyección de la Demanda Eléctrica Mensual Univariada con Modelo Híbrido</i> .....	76
<b>Figura 29</b> <i>Validación Demanda Eléctrica Mensual Univariada con Modelo Híbrido 2025</i> .....	77
<b>Figura 30</b> <i>Proyección de la Demanda Eléctrica Mensual Univariada con Modelo Prophet</i> .....	78
<b>Figura 31</b> <i>Validación Demanda Eléctrica Mensual Univariada con Prophet 2025</i> .....	78
<b>Figura 32</b> <i>Proyección de la Demanda Eléctrica Mensual Multivariada con Modelo Híbrido</i> ...	79
<b>Figura 33</b> <i>Validación Demanda Eléctrica Mensual Multivariada con Modelo Híbrido 2025</i> ....	80
<b>Figura 34</b> <i>Proyección de la Demanda Eléctrica Mensual Multivariada con Modelo Prophet</i> ...	81
<b>Figura 35</b> <i>Validación Demanda Eléctrica Mensual Multivariada con Prophet 2025</i> .....	81
<b>Figura 36</b> <i>Métricas de Error en Escala Diaria</i> .....	82
<b>Figura 37</b> <i>Métricas de Error en Escala Mensual</i> .....	83
<b>Figura 38</b> <i>Comparación con Proyecciones de la UPME</i> .....	84
<b>Figura 39</b> <i>Flujo del Pipeline</i> .....	85

**Lista de Apéndices**

<b>Apéndice A</b> <i>Software Utilizado y Recursos Técnicos</i> .....	104
---	-----

## Introducción

La electricidad se ha convertido en algo indispensable para las sociedades actuales. Akter et al. (2025) mencionan que las regiones del mundo donde carecen de suministro de energía eléctrica estable generalmente también presentan escasez de profesionales y tienen comprometidos sus estándares de salud pública. Así mismo, el Banco Mundial y la Organización Mundial de la Salud, a través del informe *Energizing Health: Accelerating Electricity Access in Health-Care Facilities*, resaltan que el acceso estable a la electricidad es un pilar para la correcta prestación de servicios de salud y, además, estiman que alrededor de 900 millones de personas en el mundo son atendidas en instalaciones con acceso a la electricidad nulo o poco confiable (Akter et al., 2025; World Health Organization et al., 2023).

Por otro lado, a pesar de que el acceso a la electricidad no garantiza por sí solo la adecuada atención sanitaria ni el crecimiento económico, Stern et al. (2019) realizaron un estudio donde encontraron que hay una fuerte correlación entre el acceso a la electricidad y el desarrollo económico. Stern et al. (2019) afirman que la electricidad hace parte del desarrollo tecnológico y es crucial en el sector industrial, lo cual cobra sentido al ver que, en la cotidianidad humana, la electricidad está presente casi en cualquier lugar al que se mira.

En el contexto colombiano, Marín et al. (2015) mencionan que alrededor del 40% del consumo de electricidad del país proviene del sector residencial y de acuerdo con el Banco de la República, la población colombiana seguirá aumentando en las próximas décadas (Banco de la República, 2024). En consecuencia, se infiere que la demanda de energía en el país seguirá aumentando y esto es coherente con el informe de la Unidad de Planeación Minero-Energética en el cual proyectan que Colombia tendrá un aumento promedio de 1.77% anualmente en su demanda entre 2025 y 2039 (Unidad de Planeación Minero-Energética [UPME], 2025).

## Planteamiento del Problema

¿Cuál es una posible solución para gestionar la creciente demanda de energía en Colombia? Una alternativa es la inversión en la planificación de recursos económicos y energéticos. Para ello, son necesarias bases sólidas con datos obtenidos mediante modelos que estiman la tendencia y magnitud de la demanda de electricidad del país en diversas resoluciones temporales (diaria y mensual). Cabe mencionar que existen consideraciones relacionadas con esta alternativa, como lo describen Toledo-Cortés et al. (2023). En su estudio, analizan el consumo de electricidad en Colombia entre 2017 y 2021 en cinco regiones. Encontraron que el clima y el tipo de usuario (residencial, comercial o industrial) influyen directamente en la tendencia y magnitud de la curva de consumo de electricidad. Se destaca que, Velásquez et al. (2009) resaltan la complejidad de la relación entre la demanda y otras variables como los avances tecnológicos que permiten mayor eficiencia en el uso de la electricidad, la climatología que puede cambiar la disponibilidad de numerosos recursos de generación y el propio crecimiento de la población. Sin embargo, Velásquez et al. (2009) también resaltan un factor clave para la presente investigación y es que gracias a los esfuerzos de múltiples investigadores para comprender la evolución de la demanda de electricidad, se ha identificado que algunas de las variables a tener en cuenta son: la temperatura, el tamaño poblacional, el crecimiento económico y el precio de la electricidad. No obstante, también exponen que la demanda puede ser estimada con técnicas univariadas, es decir, predecirla con base en su propio comportamiento histórico sin tomar en cuenta variables adicionales. Este aspecto es fundamental ya que da la posibilidad de abordar ambos enfoques para determinar cuál genera los mejores resultados en el contexto colombiano.

A pesar de las limitaciones y consideraciones mencionadas, la investigación de (Osorio, 2025) exhibe que a nivel global existen países como Turquía y Arabia Saudita, donde la modelación de la demanda eléctrica ha funcionado y que, con el adecuado acercamiento, Colombia podría ser uno de los casos donde mediante Machine Learning (ML) y análisis series de tiempo se logren estimaciones más precisas de la demanda de energía eléctrica que sirvan como apoyo a la planificación energética del país.

Este trabajo plantea la pregunta de investigación: ¿Qué desempeño tienen los modelos híbridos con ML y de series de tiempo para realizar proyecciones que den soporte a la planificación del suministro de energía en Colombia?

## Justificación

Colombia es un país cuya matriz energética está sustentada principalmente en aportes hidrológicos. A tal punto que según el Banco Mundial, para 1992 el 80% de la energía del país provenía de centrales hidroeléctricas las cuales se ven afectadas por fenómenos de variabilidad climática como El Niño, el cual se caracteriza por la reducción de los aportes hidrológicos (Rudnick & Velásquez, 2021). Entre 1992 y 1993 ocurrió un fuerte fenómeno de El Niño, que dio como resultado que el país entrara en racionamiento de energía durante aproximadamente un año (Rudnick & Velásquez, 2021). A partir de ese evento, el gobierno declaró un estado de emergencia con el Decreto 680 de 1992, debido al fuerte verano que estaba provocando un afectación al suministro de energía eléctrica (República de Colombia, 1992).

Desde entonces, gracias a modificaciones en la normatividad y a la planeación del suministro de electricidad, se apostó más por alternativas para diversificar las fuentes de energía. Sin embargo, otro episodio ocurrió entre 2014 y 2016, cuando el país enfrentó uno de los fenómenos de El Niño más largos en los últimos 60 años, y a pesar de que la dependencia de energía hidroeléctrica se había reducido, las otras fuentes de generación seguían sin poder dar abasto a la demanda de electricidad del país (Contreras, 2016). En consecuencia, para 2018 la dependencia a la generación hidroeléctrica se había reducido al 69% (Rudnick & Velásquez, 2021). Sin embargo, entre 2023 y 2024 sucedió otro episodio de El Niño que provocó un aumento en la participación de la generación térmica, específicamente con gas importado, del 31.93% en promedio, lo cual sumado con las otras fuentes de generación redujo la dependencia de las hidroeléctricas al 65.27% (Bermúdez & Restrepo, 2024).

Este es un escenario que se repite ante la inadecuada gestión de la demanda eléctrica y que desencadena situaciones críticas como racionamientos de energía y el deterioro progresivo

de los sistemas de salud y del desarrollo tecnológico y económico (Akter et al., 2025; Rudnick & Velásquez, 2021; World Health Organization et al., 2023). La electricidad es necesaria para la preservación de alimentos, medicamentos, para el funcionamiento de maquinaria industrial, para el desarrollo tecnológico, entre otros (Akter et al., 2025; Marín et al., 2015; Stern et al., 2019; World Health Organization et al., 2023). Adicionalmente se derivan: la pérdida de la confianza de inversores; pérdidas operativas en las industrias; subidas del precio de la energía debido a que las alternativas (generalmente energía térmica) son más costosas; reducción de calidad de servicios médicos, entre otras (Rudnick & Velásquez, 2021).

Es ahí donde juega un papel clave la estimación de la demanda y la detección de los picos de consumo mediante técnicas como las series de tiempo y el ML para tener soporte basado en datos al momento de invertir en la planificación de recursos económicos y energéticos, logrando así que desde cada individuo hasta las grandes industrias se beneficien del acceso estable a la electricidad incluso ante eventos climatológicos críticos.

## Objetivos

### Objetivo General

Evaluar el desempeño de dos modelos predictivos basados en series temporales y aprendizaje automático para la estimación de la demanda eléctrica y los picos de consumo en Colombia, con el propósito de generar pronósticos en resoluciones diarias y mensuales para el horizonte 2026-2029 a partir de datos entre 2015 y 2025.

### Objetivos Específicos

Determinar las dinámicas temporales y la fuerza de asociación estadística entre la demanda eléctrica, los aportes hidrológicos, el crecimiento de la población, el Producto Interno Bruto (PIB) y el volumen de los embalses, justificando la selección de las variables predictoras para los modelos de machine learning y series temporales.

Comparar el desempeño predictivo de un enfoque híbrido de descomposición aditiva basado en Machine Learning (Elastic Net y XGBoost) frente a un modelo de series temporales puro (Prophet), evaluando su precisión en resoluciones diaria y mensual mediante las métricas de error RMSE, MAPE y MASE.

Diseñar un Pipeline que integre la carga de datos, la inferencia de los modelos y la extrapolación de los pronósticos hasta 2029, garantizando la reproducibilidad y escalabilidad del sistema.

## Estado del Arte

### Machine Learning en la Demanda Eléctrica

El uso de técnicas tradicionales para la estimación de la demanda conlleva restricciones que a largo plazo no garantizan la suficiente confiabilidad ni efectividad, sumado a que en entornos dinámicos se requieren estrategias más avanzadas como el ML (Reddy et al., 2023). Adicionalmente, la literatura respalda la superioridad de algoritmos de ensamble como XGBoost (XGB) para el modelado de relaciones no lineales complejas por encima del uso de modelos individuales. De acuerdo con Huang et al. (2025), XGB procesa las variaciones extremas y los patrones irregulares, lo cual garantiza estimaciones más robustas y de alta complejidad. Contrario a modelos estándar de árboles de decisión, este modelo previene el sobreajuste y es capaz de procesar matrices con una eficiencia computacional mayor (Chang et al., 2018).

En consecuencia, la literatura defiende la implementación de modelos de ML por encima de los métodos convencionales en la generación de energía, debido a su capacidad para asimilar relaciones complejas presentes en los datos y descifrar los patrones ocultos, especialmente en grandes volúmenes de información. Esto facilita la planificación estratégica del suministro de energía eléctrica (Lee et al., 2022). La necesidad de una transición desde metodologías clásicas como SARIMA o suavizado exponencial, las cuales presentan deficiencias para capturar la complejidad de la demanda y arrastran errores que afectan la planificación (Osorio, 2025; Tabares & Velásquez, 2013). Ante dichas limitaciones, las arquitecturas con ML han ganado terreno en diversas regiones. Está el caso del uso de modelo basado en redes neuronales para estimar la demanda horaria en el departamento de Antioquia, Colombia con márgenes de error por debajo del 15%.

Finalmente, de acuerdo con Maisueche (2019), la predicción de la carga eléctrica es un aspecto fundamental para la gestión eficiente de los recursos y que gracias a la evolución computacional le permite al sector energético el uso de modelos avanzados, reemplazando las aproximaciones tradicionales. El valor agregado del ML se sitúa en su capacidad para actuar como facilitador entre la captación y procesamiento masivo de datos y la toma de decisiones que transforman las estrategias operativas del país.

### **Modelos Aditivos en la Demanda Eléctrica**

Dentro de la familia de herramientas predictivas, los enfoques de descomposición cobran importancia para el modelado de series temporales con alta estacionalidad. La demanda eléctrica exhibe variaciones cíclicas complejas según la resolución (diaria, semanal y anual), lo cual representa un desafío para su estimación directa en el largo plazo. Para abordar dicho reto, investigaciones como la de Filik et al. (2011) han demostrado la eficacia de descomponer la señal eléctrica en subelementos: la tendencia macro para capturar el crecimiento interanual y las variaciones estacionales mediante funciones sinusoidales. Este principio de descomposición aditiva representa la base de algoritmos modernos como Prophet. Gracias al aislamiento de la tendencia y de los patrones estacionales, este tipo de algoritmos estabiliza la varianza del modelo y le permite proyectar la demanda eléctrica a varios años a la par que mitiga el riesgo de sobreajuste del modelo.

La vigencia y pertinencia de esta representación matemática ha sido implementada por investigaciones recientes. Bansal et al. (2025) demostraron que codificar las variables temporales mediante funciones sinusoidales (el mismo mecanismo que usa Prophet para modelar la estacionalidad mediante series de Fourier) resuelve el reto de la discontinuidad temporal, tales como un salto numérico de la hora 23:59 a la hora 0:00. En su estudio sobre la demanda

energética, los autores probaron que, al conservar la continuidad de los patrones de consumo mediante la transformación sinusoidal, los modelos obtuvieron errores de hasta 12.6% en sus errores promedio frente al enfoque sin codificación. Esto justifica la adopción de algoritmos aditivos que se estructuran con base en la codificación armónica para aumentar la precisión en la estimación de la demanda eléctrica.

La consolidación de estos enfoques matemáticos se materializó con la introducción de Prophet, un algoritmo que fue desarrollado por investigadores de Facebook e ideado para estimación de series temporales (Taylor & Letham, 2017). Este modela de manera independiente la tendencia, la oscilación estacional (mediante series de Fourier) y el impacto de eventos atípicos. Para el caso del mercado eléctrico resulta de gran valor al modelar la demanda eléctrica, la cual varía según el día de la semana y mes del año (Asoenergía, 2020). En consecuencia, Prophet se convierte en una arquitectura prometedora para obtener pronósticos robustos y adaptables en un sistema de alta volatilidad debido a su dependencia hidroeléctrica como Colombia.

### **Univariado vs Multivariado**

En el debate sobre la dimensionalidad adecuada para el pronóstico energético, generalmente se apoya el principio de parsimonia, el cual establece que los modelos más simples generalizan y extrapolan a futuro mejor que modelos más complejos incluso si estos últimos se ajustan mejor durante la fase de entrenamiento (Higginbotham & Walker, 2026). Investigaciones como la realizada por Lee et al. (2022), demostraron que es posible obtener proyecciones de alta precisión en horizontes de hasta 12 meses empleando estrictamente enfoques univariados. Tras la evaluación del consumo eléctrico de siete países, cada uno con condiciones socioeconómicas diferentes, los autores evidenciaron que modelos basados en series de tiempo logran capturar la

incertidumbre y estabilizar el error basándose exclusivamente en el comportamiento histórico de la demanda, lo cual mitiga la necesidad de incorporar variables exógenas.

Históricamente el enfoque que defiende la parsimonia ha tenido respaldo en la literatura. Investigadores como Velásquez et al. (2009) establecieron que la preferencia por técnicas univariadas en la modelación de la demanda eléctrica se da como consecuencia a evitar la incorporación de variables que exigen supuestos adicionales sobre su evolución futura y, termina inyectando ruido y aumentando la incertidumbre de los pronósticos a largo plazo.

Sumado a ello, el contexto colombiano presenta un desafío al incorporar variables como el PIB en los modelos predictivos debido a la baja frecuencia de medición de este frente a la alta frecuencia de la demanda eléctrica. Esto refuerza la viabilidad del enfoque univariado en determinados contextos gracias a que evitan la introducción de ruido adicional y permiten que el modelo exprese la autocorrelación de la serie. Sin embargo, no lo descarta por completo y solo a través de la experimentación se debería definir qué acercamiento se adapta mejor a un determinado problema (Barrientos et al., 2023).

### **Vacío de Conocimiento**

A pesar de la gran abundancia de algoritmos predictivos, la literatura coincide en que no existe un modelo universal para el pronóstico de la demanda eléctrica. El rendimiento de cada arquitectura varía según el contexto y la volatilidad de cada región (Lee et al., 2022). En el caso específico de Colombia, instituciones oficiales encargadas de la planificación energética como la UPME, todavía basan sus proyecciones en metodologías tradicionales sin la incorporación de inteligencia artificial, demostrando un rezago frente a los estándares globales (Barrientos et al., 2023). Además, en el contexto local, el esfuerzo para implementar ML es disperso y carece del

escalamiento nacional. La falta de un puente entre las investigaciones y las instituciones dificultan consolidar un sistema predictivo moderno y estandarizado.

Dicho estancamiento puede deberse a las barreras en la transformación digital. Maisueche (2019) identificó que la incorporación de modelos de ML en los entornos industriales convencionales está frenada principalmente por la resistencia al cambio de las organizaciones, el costo que se percibe al reestructurar los procesos y la falta de personal capacitado para el desarrollo de modelos predictivos. Así mismo, un gran riesgo para que se logre adoptar el uso de estos modelos es su dependencia a la calidad y cantidad de datos históricos. Cuando alguna organización no cuenta con estándares en el almacenamiento de sus datos, la implementación de algoritmos avanzados resulta poco eficaz comparada con métodos clásicos (Maisueche, 2019).

De regreso al contexto colombiano, Barrientos et al. (2023) destacan que el sistema eléctrico colombiano tiene un riesgo latente debido a su alta dependencia de fuentes hidroeléctricas, las cuales están expuestas por factores como El Niño. Además, concluyen que una de las grandes brechas en la investigación del país es la utilización de modelos predictivos que incorporen variables como los volúmenes de agua en los ríos y las reservas de los embalses.

En consecuencia, los estudios comparativos que evalúan múltiples modelos bajo las mismas condiciones resultan de valor para la literatura científica (Lee et al., 2022). La presente investigación responde de manera directa estos vacíos, buscando determinar qué arquitectura (univariada o multivariada, aditiva o híbrida) ofrece la mayor robustez y precisión para el Sistema Interconectado Nacional de Colombia.

## Marco Teórico

### Electricidad

La electricidad es una propiedad fundamental de la materia que se asocia al movimiento de partículas presentes en los átomos llamadas electrones. Se manifiesta mediante la atracción o la repulsión entre partículas (RAE, s. f.; Universidad ORT, s. f.). Su descubrimiento se remonta a hace más de 2000 años cuando el filósofo y matemático Tales de Mileto observó que el ámbar es capaz de atraer fragmentos de papel cuando es frotado y, desde entonces cientos de investigadores han generado aportes para su entendimiento y aprovechamiento (Gándara, 2024; Hernández, 2024). La electricidad tiene características únicas, algunas de ellas son:

- **Carga:** Es una propiedad de algunas partículas al interior de los átomos. Existen cargas positivas (protones) y cargas negativas (electrones). Además, las cargas del mismo tipo se repelen mientras que las de tipo opuesto se atraen (Pereira, 2016).
- **Voltaje:** Es una medida de la cantidad de energía que se requiere para mover una carga de un lugar a otro. También se le llama tensión eléctrica o diferencia de potencial debido a que cuanto mayor sea la energía requerida, mayor será el impulso que tendrán las cargas para desplazarse (Jiménez, 2025; Pereira, 2016).
- **Corriente:** Es el movimiento de los electrones a través de un material conductor, por ejemplo, un cable, y que ocurre debido a una diferencia de potencial. Siempre tiene una magnitud y dirección. La corriente puede ser continua (CC) en cuyo caso el movimiento es en un solo sentido o alterna (CA) en la cual el sentido de movimiento de los electrones cambia periódicamente (Jiménez, 2025; Pereira, 2016).

Al proceso mediante el cual otros tipos de energía (como la mecánica, térmica o química) se transforman en electricidad se le llama generación de energía eléctrica (Jiménez, 2025). A su vez, la generación de electricidad se categoriza en:

- **Renovable:** Son aquellas que provienen de recursos “inagotables” o que se recuperan continuamente y cuyo impacto en el ambiente es bajo como la radiación solar, el movimiento del viento y del agua, entre otras (Área Metropolitana del Valle de Aburrá, s. f.; ENEL, 2025).
- **No Renovable:** Son aquellas cuya regeneración puede tomar millones de años, por lo cual una vez agotadas dejan de ser accesibles en el corto plazo por los seres humanos. Además, su uso conlleva un mayor deterioro ambiental desde su proceso de extracción hasta los desechos producidos luego de la generación de energía. Algunos ejemplos son el petróleo, el carbón y el gas natural (ENEL, 2025; Universidad Europea, 2025).

### **Sistema Interconectado Nacional**

El Sistema Interconectado Nacional (SIN) es el sistema compuesto por las plantas de generación, la red de interconexión, las redes regionales e interregionales y las cargas eléctricas de los usuarios (República de Colombia, 1994; Muñoz Romero, 2024). En Colombia, la planeación y coordinación del SIN está a cargo de XM S.A. E.S.P., la cual, para lograr su adecuada supervisión y control de la red, emplean una infraestructura de alta disponibilidad basada en sistemas SCADA/EMS (Muñoz Romero, 2024; Pinzón et al., 2020). XM captura la información por niveles y, a través de canales de comunicación los datos fluyen hacia centros de control regional y finalmente un centro de control nacional. Esta arquitectura procesa la telemetría de más de 12,000 kilómetros de líneas de transmisión en Colombia y almacena la información en servidores históricos de alta confiabilidad (Pinzón et al., 2020). Desde la

perspectiva del modelado predictivo, esto aumenta la integridad y continuidad de las series temporales de la demanda eléctrica para su utilización en algoritmos de series de tiempo y ML.

### **Crecimiento Poblacional en Colombia**

El crecimiento de la población en el territorio colombiano no ha sido uniforme. Los departamentos con la escolaridad más baja y la mayor pobreza son también donde se tiene la más alta tasa de fecundidad (Pérez, 2006). Y aunque en términos generales la cantidad de nacimientos se ha reducido progresivamente, por razones como el aumento de métodos anticonceptivos (Colmenares & Pardo, 2021; Pérez, 2006), el estudio de Colmenares y Pardo (2021) exhibe que la población sigue aumentando. Colombia pasó de tener alrededor de 14 millones de habitantes en 1958 a más de 44 millones en 2014. Además, de acuerdo con las proyecciones del Departamento Administrativo Nacional de Estadística (DANE) y del Departamento de Asuntos Económicos y Sociales de las Naciones Unidas, para 2050 se estiman por encima de 56 millones de habitantes en Colombia (Departamento Administrativo Nacional de Estadística [DANE], 2023; Department of Economic and Social Affairs, 2024).

Cabe resaltar que, aunque Colmenares y Pardo (2021) exhiben que las proyecciones de la población colombiana en varias ocasiones han presentado sobreestimaciones de hasta más del 10%, el aumento poblacional es un hecho y se espera que siga sucediendo en las próximas décadas (Banco de la República, 2024; DANE, 2023). Este crecimiento sostenido actúa como un factor exógeno que empuja la línea base de la demanda de energía eléctrica y justifica el análisis de su inclusión como variable predictora para modelar tendencia en el mediano y largo plazo en los algoritmos de series de tiempo.

## Series de Tiempo

Una serie de tiempo es un conjunto de datos ordenados cronológicamente y que permiten realizar análisis estructurales y predictivos de una variable de interés (DANE, 2016; Silva et al., 2026). Las técnicas con series de tiempo han sido ampliamente usadas para el pronóstico de la demanda eléctrica por múltiples investigadores (Hinman & Hickey, 2009). Los modelos basados en dichas técnicas generalmente se componen de los siguientes elementos:

- **Tendencia:** Es el comportamiento general de la serie en largo plazo, ya sea crecer, decrecer o permanecer constante y no necesariamente de manera lineal (Mathworks, s. f.).
- **Estacionalidad:** Son patrones que se repiten de manera regular cada cierto periodo, ya sea de manera diaria, mensual, entre otros. Además, una misma serie de tiempo puede presentar múltiples patrones estacionales (Silva et al., 2026; The Pennsylvania State University, 2024).
- **Ruido:** Está asociado a la incertidumbre y en muchos sistemas es algo inherente. También se le puede asociar con la parte inexplicable de la serie de tiempo y que carece de una estructura clara (da Silva et al., 2019; Silva et al., 2026).

En su estudio, Silva et al. (2026) exhiben dos maneras de abordar una descomposición de las series de tiempo: aditiva y multiplicativa. La elección debe basarse en la existencia de una relación de proporcionalidad entre las fluctuaciones de la estacionalidad y la magnitud en la cual oscilan los datos para un determinado periodo. Es decir, si la variable conserva su amplitud a lo largo del tiempo se puede usar el enfoque aditivo. Caso contrario, si la amplitud cambia, se recomienda el enfoque multiplicativo. Además, al aplicar una transformación logarítmica a los componentes, se estabiliza la varianza de las observaciones a lo largo del tiempo y

posteriormente regresar a los datos originales mediante la operación inversa lo cual funciona como un puente entre ambos enfoques (Dagum, 2010; Taylor & Letham, 2017).

Respecto a la manera de abordar cada componente, Hinman y Hickey (2009) mencionan que la tendencia suele trabajarse mediante un ajuste determinístico, por ejemplo, mediante una regresión lineal. En cambio, la estacionalidad suele ser más compleja. Por ello, se mencionan que un enfoque mediante descomposiciones de Fourier, las cuales permiten representar dicho componente en términos de funciones trigonométricas como senos y cosenos (llamados armónicos), brindan resultados significativamente mejores (Hinman & Hickey, 2009; Valero Fandiño, 2013)

En otras palabras, de acuerdo con Valero Fandiño (2013), los valores de una serie de tiempo ( $y_t$ ) para cada instante ( $j$ ) se pueden obtener como la suma de los armónicos ( $f$ ) que lo componen (Ecuación 1).

$$y_t(j) = \sum_f^{\infty} y_f(j) \quad (1)$$

donde  $y_f(j)$  es el valor del armónico  $f$  para un tiempo  $j$ . Así mismo, desde la perspectiva del procesamiento de señales, cada armónico se caracteriza como una función sinusoidal de la forma (Ecuación 2):

$$y_f(j) = A \cdot \left[ \cos \left( \frac{2 \cdot \pi \cdot f \cdot j}{T_{max}} + \phi_f \right) \right] \quad (2)$$

Estimar de manera directa la amplitud ( $A$ ) y el desfase ( $\phi$ ) es un problema no lineal complejo que para solucionarlo, Valero Fandiño (2013) define  $\theta = \frac{2 \cdot \pi \cdot j}{T_{max}}$  y aplica la identidad trigonométrica que le permite reescribir el armónico separando el desfase en dos parámetros (Ecuación 3):

$$y_f(j) = \alpha_f \cdot \cos(\theta \cdot f) - \beta_f \cdot \sin(\theta \cdot f) \quad (3)$$

donde  $\alpha_f = A_f \cdot \cos(\theta_f)$  y  $\beta_f = A_f \cdot \sin(\theta_f)$ . Los parámetros  $\alpha_f$  y  $\beta_f$  se calculan de manera analítica mediante la Transformada de Fourier Directa Discreta (Valero Fandiño, 2013). Sin embargo, en el pronóstico de series de tiempo este enfoque se transforma en lo que se llama “regresión armónica”. Akdi et al. (2020) demostraron en su investigación sobre el consumo de energía diaria que, ante la presencia de un factor periódico, se obtienen mejores resultados al reemplazar la señal original por una combinación lineal de senos y cosenos. De tal manera que, en lugar de calcular analíticamente los coeficientes, el modelo estima los coeficientes mediante regresión.

Esta es justo la base que Hyndman y Athanasopoulos (2018) estandarizan para pronósticos estadísticos complejos. Bajo su enfoque, la Ecuación 3 se adapta cambiando la cantidad de armónicos hasta un número máximo  $k$  y se usan funciones trigonométricas puras como variables predictoras independientes. Tanto así que Monteiro et al. (2025) desarrollaron una metodología híbrida para proyectar precios del mercado energético evitando cálculos analíticos clásicos y, en su lugar, incorporaron términos de Fourier directamente en la etapa de ingeniería de características. Allí, demostraron que la inyección de componentes periódicos como variables predictoras permite a los algoritmos modelar los ciclos estacionales, incluso ante la presencia de múltiples frecuencias en simultáneo.

Con base en ello, la implementación de la regresión armónica para la extracción de características estacionales, de acuerdo con la formulación de Hyndman y Athanasopoulos (2018), se construye de manera iterativa aumentando la frecuencia para un periodo estacional  $m$ . De manera general para un armónico  $k$ , los términos trigonométricos en el instante  $t$  están dados por (Ecuación 4 y 5):

$$x_{sin,k,t} = \sin\left(\frac{2 \cdot \pi \cdot k \cdot t}{m}\right) \quad (4)$$

$$x_{cos,k,t} = \cos\left(\frac{2 \cdot \pi \cdot k \cdot t}{m}\right) \quad (5)$$

Al aumentar la cantidad de armónicos  $k$ , se tiene una mayor flexibilidad que permite ajustarse a patrones complejos. No obstante, como advierte Moskalev (2019) en su investigación, incorporar demasiados componentes trigonométricos provoca sobreajuste severo, ya que el modelo memoriza el ruido de la serie. Restringir este parámetro obedece al principio estadístico de parsimonia. Sumado a ello, la selección del número máximo de armónicos está acotada de manera estricta según el límite de Nyquist. En este, se establece que la frecuencia máxima que puede ser capturada sin distorsión equivale a la mitad de la frecuencia de muestreo. Por ende, para un periodo estacional  $m$ , la restricción dicta que  $k \leq m/2$  (Universidad de Indiana, s. f.).

Por otro lado, el término del error o residuo, el cual es caótico de manera intrínseca, puede ser modelado mediante algoritmos de ML, sacando provecho de las capacidades de dichos modelos para capturar patrones no lineales. Ahí es donde cobran relevancia los modelos híbridos que aprovechan las herramientas clásicas sumadas a los algoritmos de ML. De acuerdo con da Silva et al. (2019) el proceso consiste en estimar la parte “lineal” y restarla de los valores reales. De esta manera se obtiene el ruido para cada punto de la serie. Posteriormente, el algoritmo de ML aprende a modelar los errores y generar pronósticos de estos. Mediante lo cual se obtiene cada componente para posteriormente reconstruir la serie de tiempo y obtener sus estimaciones.

### **Prophet**

En 2017 fue liberado un modelo de series de tiempo llamado Prophet, el cual está diseñado de tal manera que el ajuste de sus parámetros es intuitivo lo cual le facilita ser adaptado

a múltiples problemas (Taylor & Letham, 2017). Prophet combina tres componentes principales de los modelos de series de tiempo (Ecuación 6):

$$y(t) = g(t) + s(t) + h(t) + \epsilon_t \quad (6)$$

Donde  $g(t)$  modela cambios no periódicos en la serie (tendencia),  $s(t)$  modela cambios periódicos en la serie (estacionalidad) y  $h(t)$  representa el peso de las festividades que ocurren en fechas irregulares durante uno o más días. Respecto el término del error ( $\epsilon_t$ ), Taylor y Letham (2017) indican que incorpora cambios que el modelo no logra captar y asumen que se distribuye normalmente.

Prophet se asemeja a los modelos aditivos generalizados, los cuales se construyen a partir de sumas de funciones simples más pequeñas que tienen una mayor flexibilidad, lo cual a su vez tienen la ventaja de descomponerse a medida que se identifican nuevas estacionalidades (Miller, 2025; Taylor & Letham, 2017). Sin embargo, en diversos estudios se ha encontrado que a pesar de su alta precisión en periodos de tiempo cortos, sus capacidades se pueden ver afectadas a medida que el horizonte temporal avanza (Aditya Satrio et al., 2021). Los principales hiperparámetros de Prophet son (Libriawan et al., 2025; Meta Open Source, s. f.):

- `changepoint_prior_scale`: Permite controlar la sensibilidad de la tendencia ante cambios. Cuanto más grande sea su valor el modelo será más reactivo y hará que la tendencia sea más flexible, mientras que valores bajos hacen que Prophet suavice la tendencia.
- `seasonality_prior_scale`: Ajusta la fuerza del componente estacional e incorpora penalizaciones para evitar sobreajuste al modelo.
- `seasonality_mode`: Especifica si el efecto de la estacionalidad es sumado o multiplicado a la tendencia. Por defecto es aditiva, pero si la estacionalidad cambia demasiado de inicio a fin se recomienda usar multiplicativa.

- `n_changepoints`: Indica cuántos puntos potenciales de cambio de trayectoria debería considerar el modelo para adaptarse a variaciones en el largo plazo. Por defecto Prophet usa 25 puntos de cambio potencial distribuidos de manera uniforme en el primer 80% de la serie de tiempo.

## **Inteligencia Artificial**

La Inteligencia Artificial (IA) es una herramienta que le permite a las máquinas simular la capacidad de pensamiento de un ser humano en tareas como aprender, resolver problemas, e incluso la creación de contenido escrito y audiovisual (Osorio, 2025; Stryker & Kavlakoglu, s. f.). La IA ha evolucionado gradualmente desde sus primeras bases en 1943 cuando se propuso el concepto de neuronas artificiales y en 1950 cuando el matemático Alan Turing publicó su estudio cuestionando si las máquinas podían pensar (Turing, 1950). El autor menciona que eventualmente las máquinas serían capaces de competir con los humanos en los campos intelectuales.

Para 1956 un grupo de científicos se reunieron en la Universidad de Dartmouth (ubicada en Estados Unidos). A este encuentro se le considera el primero en introducir formalmente el concepto y ese mismo año se creó el primer programa de IA funcional en la historia (Cordeschi, 2007; Stryker & Kavlakoglu, s. f.). De ahí en adelante los descubrimientos e implementación de la IA no ha dejado de avanzar. Ya para 2024 John Hopfield y Geoffrey Hinton ganaron el premio nobel de física por su trabajo en redes neuronales artificiales. En la actualidad dichas redes neuronales les da la capacidad a las máquinas de interpretar imágenes y hasta tener conversaciones con humanos. Los descubrimientos de John y Geoffrey son la base para la existencia de herramientas como el popular ChatGPT (B. Li & Gilbert, 2024).

Dentro de la IA se encuentra un subgrupo llamado aprendizaje automático o también llamado Machine Learning que consiste en técnicas estadísticas para lograr que las máquinas aprendan a partir de la identificación automática de patrones en datos sin que sean explícitamente programadas para lograrlo (Maisueche, 2019; Osorio, 2025). A pesar de que no será abordado en este trabajo, cabe mencionar que dentro del ML hay un subgrupo llamado Aprendizaje Profundo (Deep Learning) y que también tiene una poderosa capacidad para el procesamiento de datos pero que es más exigente en términos computacionales y de la cantidad de datos que requieren para un adecuado funcionamiento (Oluwasakin et al., 2023). Respecto al ML, la cuestión es ¿cómo aprende un modelo de ML? Alzubi et al. (2018) explican los pasos que sigue todo modelo genérico de la siguiente manera:

- **Recolección y preparación de datos:** Se obtienen datos en un formato que pueda ser usado como entrada para el modelo.
- **Selección de características:** Se remueven las características irrelevantes para abordar el problema seleccionado.
- **Selección del algoritmo:** Existen múltiples algoritmos, y no todos funcionan bien en todos los problemas. Una correcta selección del algoritmo influye directamente en los resultados.
- **Selección de hiperparámetros:** Se refiere al ajuste manual de algunas características del modelo seleccionado.
- **Entrenamiento:** El modelo se ejecuta con una parte de los datos para encontrar patrones en su interior.
- **Evaluación:** Antes de poder desplegar el modelo, se realiza la etapa de validación para determinar qué tan bueno fue el modelo para adaptarse al problema.

Entre los múltiples paradigmas del ML, algunos de los principales son (Alzubi et al., 2018; Manrique, 2020; Osorio, 2025):

- **Supervisado:** Se le muestran las respuestas esperadas al algoritmo a partir de un conjunto de datos de entrada y este encuentra los patrones y desarrolla las transformaciones para conseguir dichas salidas. Ejemplo de ello es la estimación de datos temporales (regresión) y la clasificación de datos en grupos conocidos (Jiang et al., 2020).
- **No Supervisado:** El algoritmo debe encontrar los patrones en los datos sin saber cuál es la salida correcta. Un caso de uso es la segmentación de pacientes en uno u otro grupo de enfermedades mentales (Jiang et al., 2020).
- **Por refuerzo:** Está basado en un sistema de recompensas y penalizaciones. El algoritmo debe encontrar las salidas que le generan la mayor cantidad de recompensas y la menor cantidad de penalizaciones. Algunos casos de uso incluyen sistemas de recomendación de productos, estrategias para tratamientos médicos, orden de entrega de pedidos, entre otros (Y. Li, 2019).
- **Aprendizaje ensamblado:** Surge como resultado de unir las predicciones de varios modelos individuales o, dicho de otra manera, la combinación de muchos modelos débiles puede resultar en un modelo fuerte (Ahmed et al., 2024).

El foco de este trabajo es el paradigma de los modelos supervisados, específicamente los modelos de regresión cuyo principal objetivo es predecir valores numéricos continuos (Alzubi et al., 2018; Maisueche, 2019). De manera puntual, se usan Elastic Net para la tendencia y en el Gradient Boosting para el ruido:

- **Elastic Net:** Es un procedimiento de regularización de la regresión lineal. La regularización permite ajustar un modelo para evitar que memorice los datos de entrenamiento y

tenga una mayor capacidad de generalización. Para ello, de fondo se basa en el concepto del intercambio del sesgo y la varianza, en el cual se dice que a medida que aumenta la cantidad de variables predictoras se reduce el sesgo, pero aumenta la varianza, y viceversa (Chukwura & Chinenye, 2023). Elastic Net puede aplicar dos penalizaciones: 1) Reduce el peso que tienen las variables predictoras sobre la variable objetivo, pero sin llevarlos a 0, lo cual ayuda a prevenir la multicolinealidad (L1); 2) Reduce el peso de algunas variables predictoras a 0 para eliminar aquellas que son menos importantes, lo cual ayuda a conservar solo las más relevantes (L2) (Chukwura & Chinenye, 2023; Ogutu et al., 2012).

- Extreme Gradient Boosting (XGB): Es un algoritmo basado en aprendizaje por ensamble. Usa el enfoque de Boosting, en el cual se usan numerosos árboles de decisión en serie y luego de entrenamiento se ajustan los parámetros del modelo según los resultados de la iteración inmediatamente anterior. Con dicho ajuste busca corregir los errores de manera progresiva y finalmente la combinación de todos los árboles genera una única salida. Este modelo aplica técnicas que previenen el sobreajuste y reducen el error entre los valores reales y los valores estimados (Ahmed et al., 2024; Chang et al., 2018; Reddy et al., 2023).

En consecuencia, los modelos deben ser evaluados mediante métricas que permitan cuantificar sus capacidades para captar la complejidad de los datos. Algunas de las métricas usadas en problemas de regresión son (Botchkarev, 2019):

- Root Mean Square Error (RMSE): Es una de las más usadas en problemas de regresión (Lee et al., 2022). Es la raíz de la suma de las diferencias entre los valores reales y los valores pronosticados (el error) elevados al cuadrado y divididos por el total de observaciones, es decir, un RMSE más bajo indica un menor error. Además, siempre es un valor positivo y cuanto

más cercano a 0, mejor es el desempeño del modelo y se obtiene de acuerdo con la Ecuación 7 (Bi et al., 2019; Jamil & Akhtar, 2017).

$$RMSE = \sqrt{\sum_{t=1}^n \frac{(\hat{y}_t - y_t)^2}{n}} \quad (7)$$

donde  $y_t$  es el valor real,  $\hat{y}_t$  es el valor estimado en el tiempo  $t$  y  $n$  es el total de observaciones.

- Mean Absolute Percentage Error (MAPE): Se basa en obtener el promedio del valor absoluto de los errores (error absoluto medio) en términos relativos lo cual lo hace fácil de interpretar ya que cuanto más cerca de cero indica un mejor desempeño del modelo y ya ha sido usada en problemas del pronóstico de consumo de electricidad (Ecuación 8) (Myttenaere et al., 2016; Zhou et al., 2018).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{y_t} \quad (8)$$

donde  $y_t$  es el valor real,  $\hat{y}_t$  es el valor estimado en el tiempo  $t$  y  $n$  es el total de observaciones.

- Mean Absolute Scaled Error (MASE): Es considerado el mejor para pronósticos según Hyndman y Koehler (2006) debido a que es fácil de interpretar y poco sensible ante la presencia de valores atípicos. Al igual que MAPE, se basa en el error absoluto medio, pero se divide entre el error obtenido del método de pronóstico de Naïve (Ecuación 9), en el cual se propone que un pronóstico será igual que su última observación registrada. Un MASE por debajo de 1 indica que el modelo tiene en promedio un mejor desempeño que simplemente repetir el último dato observado, mientras que lo opuesto sucede con valores mayores a 1 en los cuales se infiere que sería mejor simplemente usar el método de Naïve (Hyndman & Koehler, 2006).

$$MASE = \frac{\frac{Y_t - F_t}{y_t}}{\frac{1}{n-1} \sum_{i=2}^n |Y_i - Y_{i-1}|} \quad (9)$$

donde  $Y_t$  es el valor real,  $F_t$  es el valor estimado en el tiempo  $t$  relacionado al periodo de validación,  $Y_i$  es el valor real,  $Y_{i-1}$  es el valor real observado en un periodo inmediatamente anterior en el tiempo  $i$  relacionado con el periodo de entrenamiento y  $n$  es el total de observaciones.

En ese orden de ideas, uno de los procesos mediante el cual se buscan las mejores combinaciones de hiperparámetros que permiten al modelo optimizar sus métricas es búsqueda por grilla (Grid Search), que consiste en una búsqueda sistemática donde se evalúan todas las posibles combinaciones dentro de un intervalo especificado con el fin de identificar la configuración con el mayor rendimiento y es un paso clave en la reproducibilidad del modelado con ML (Hussain et al., 2025; Shivashankar et al., 2025).

### **Pipelines Analíticos**

Un Pipeline en ML alude al conjunto de salidas generadas por los procesos que van desde la exploración y preprocesamiento de datos hasta la selección de algoritmos, configuración y validación de hiperparámetros. Y se sustentan en la necesidad de codificar y garantizar el flujo de trabajo en proyectos de ML (Zheng & Stodden, 2024).

En el escenario de las series de tiempo, el diseño e implementación de un pipeline es crítico para mitigar una fuga de datos (*data leakage*). Esta sucede cuando información del conjunto de validación es introducida al modelo durante su etapa de validación lo cual elimina el propósito de separar los datos en entrenamiento y validación, lo cual puede llevar a inflar las capacidades del modelo y reducir la reproducibilidad (Rosenblatt et al., 2024; Zhao et al., 2025).

Por ello, al encapsular las transformaciones dentro de un flujo controlado, se garantiza la integridad del conjunto de validación.

Otra virtud de la implementación de un Pipeline se materializa en la gestión y almacenamiento de modelos. Dado que procesos como Grid Search son computacionalmente demandantes, es recomendable que los valores óptimos de cada modelo sean almacenados físicamente. A ello se le llama persistencia, y elimina la necesidad de ejecutar entrenamientos desde cero y otorgando al sistema de reproducibilidad y eficiencia operativa para ejecuciones a largo plazo (Shivashankar et al., 2025; Zhao et al., 2025).

## Metodología

### Enfoque Metodológico

El presente trabajo toma como referencia la metodología CRISP-DM, la cual es una de las más usadas en proyectos de minería de datos (Schröer et al., 2021). Consta de varias etapas que van desde el entendimiento del problema hasta el despliegue del modelo. Fue usado el lenguaje de programación Python que a través de sus múltiples librerías (Pandas, Scipy, Statsmodels, Scikit-Learn, entre otras), permite abordar el problema de inicio a fin (Desai et al., 2021; Maryasin & Lukashov, 2020; Toledo-Cortés et al., 2023). Cabe mencionar que, el proyecto abarca tres fases principales, cada una asociada a dar cumplimiento a un objetivo específico.

### Fase 1 Identificación y Preparación de los Datos

#### *Entendimiento del Problema y Obtención de Datos*

Para la estimación de la demanda de electricidad y la identificación de los picos de consumo en Colombia en resoluciones diaria y mensual mediante modelos de series de tiempo e híbridos con ML, se definió un horizonte de análisis comprendido entre el 1 de enero de 2015 y el 31 de diciembre de 2025. El conjunto se dividió cronológicamente: el periodo 2015 a 2024 se designó para entrenamiento, mientras que el año 2025 para validación.

Las fuentes de datos fueron la compañía XM, el DANE y UPME. Se extrajeron datos históricos de la demanda real de energía, los aportes hidrológicos y el volumen de los embalses mediante la librería oficial PydataXM, la cual provee acceso a datos horarios, diarios y mensuales (Tabla 1) (XM SA ESP, s. f.-b). Debido a que la demanda es extraída de manera horaria, fue agregada mediante suma para llevarla a resolución diaria.

**Tabla 1***Variables Obtenidas de XM*

Nombre	Descripción	Unidad	Escala
	Demanda de usuarios regulados y no regulados que hacen		
DemaReal	parte del Sistema Interconectado Nacional (no incluye Alumbrado Público)	kWh	Horaria
	Caudales en energía de los ríos que aportan agua a algún embalse del Sistema Nacional Interconectado		
AporEner		kWh	Diaría
	Porcentaje de volumen almacenado en el embalse por encima del Nivel Mínimo Técnico		
PorcVoluUtilDiar		%	Diaría

*Nota.* Datos obtenidos a través de la API PydataXM ((XM SA ESP, s. f.-b).

Respecto a los indicadores económicos y demográficos, se obtuvo del DANE la información de la población basada en el censo nacional más reciente (2018), la cual se encuentra dividida en los periodos 1950 a 2017 y 2018 a 2070. Por lo cual, fueron unificados y filtrados al periodo de análisis. Así mismo, se obtuvo la información del Producto Interno Bruto (PIB) en precios constantes, que según se indica en su boletín técnico (DANE, 2026a), tiene un proceso de ajuste donde no se toma en cuenta la inflación lo cual permite comparar objetivamente valores de diferentes años (Tabla 2).

**Tabla 2***Datos Obtenidos del DANE*

Nombre	Escala temporal
Serie nacional de población por área, para el periodo 1950-2017 <sup>a</sup>	Anual
Serie nacional de población por área, para el periodo 2018-2070 <sup>a</sup>	Anual
PIB a precios constantes <sup>b</sup>	Trimestral

*Nota.* Todos los datos de la tabla fueron extraídos del portal DANE.

<sup>a</sup>(Departamento Administrativo Nacional de Estadística, s. f.). <sup>b</sup>(Departamento Administrativo Nacional de Estadística, 2026b).

Finalmente, se recolectaron los datos de la UPME (Tabla 3). Estos no fueron analizados en la fase descriptiva puesto que corresponden a proyecciones de la demanda en escala mensual y anual hasta diciembre de 2039, por lo cual, serán de utilidad en la Fase 2 para evaluar el desempeño de los modelos usados. En dicha fase se realiza la visualizan las estimaciones del mejor modelo obtenido frente a lo proyectado por una entidad gubernamental, lo cual permite comparar los panoramas de la demanda eléctrica desde perspectivas diferentes.

**Tabla 3***Datos Obtenidos de la UPME*

Nombre	Formato
Anexo – Resultados de proyección de demanda de energía eléctrica y potencia máxima Rev. Julio 2025 (excel) <sup>a</sup>	xlsx
Proyección de demanda de energía eléctrica y potencia máxima a escala Nacional y por áreas eléctricas con resolución anual y mensual <sup>b</sup>	pdf

*Nota.* Información publicada y revisada por la UPME en julio de 2025.

<sup>a</sup>(Unidad de Planeación Minero Energética, 2025c). <sup>b</sup>(Unidad de Planeación Minero Energética, 2025a).

### ***Análisis Exploratorio y Preparación de los Datos***

Se ejecutó un análisis exploratorio de datos para identificar la dinámica temporal, las tendencias, la estacionalidad y la correlación de la demanda consigo misma y con variables exógenas. Durante esta etapa, se consolidaron diferentes resoluciones temporales, ya que la demanda se encuentra en escala horaria, la escala más fina, y todas las demás variables van de escala diaria a escala anual. Por ende, en el proceso de remuestreo de la demanda para que coincida con las demás variables, se analizó cada una (diaria, mensual, trimestral y anual) con las variables disponibles. Para ello se tuvieron múltiples consideraciones: 1) la medida de agregación de demanda horaria a demanda diaria fue la suma; 2) con el fin de analizar un posible efecto de rezago sobre la demanda, las correlaciones incluyen un desfase positivo (mover  $n$  periodos hacia adelante la demanda) para determinar si los aportes, volumen o cualquier otra variable en el mes  $m$  tienen efecto en la demanda en el mes  $m+n$ .

Para calcular la correlación fue usado el método de Spearman debido a que no asume que los datos tengan normalidad y es robusto ante valores atípicos (Schober et al., 2018). Cabe mencionar, que según el rango en que se encuentre el valor de la correlación, esta se puede interpretar desde despreciable hasta muy fuerte (Tabla 4).

**Tabla 4**

*Interpretación del Coeficiente de Correlación*

Valor del coeficiente	Interpretación
0 a 0.1	Despreciable
1 a 0.39	Débil
0.4 a 0.69	Moderada
0.7 a 0.89	Fuerte
0.9 a 1	Muy fuerte

*Nota.* Adaptado de (Schober et al., 2018).

Con base en los hallazgos, se procedió a la ingeniería de características. Se aplicaron transformaciones logarítmicas y se calcularon los términos sinusoidales para capturar la estacionalidad. Adicionalmente, para modelar el ruido, se extrajeron variables temporales auxiliares. En la escala diaria, se codificaron el mes, el día de la semana y un indicador binario para distinguir días laborales de días festivos y fines de semana, dada su influencia en las disminuciones de la demanda. Para la escala mensual, la codificación se limitó al mes del año y a la cantidad de días hábiles y días festivos del mismo.

## Fase 2 Comparación y Experimentación de Modelos

### *Arquitectura del Modelo Híbrido*

Se implementó una arquitectura híbrida de dos capas que se sustenta en la descomposición aditiva. Dado que la demanda diaria presentó varianza no constante, se aplicó inicialmente una transformación logarítmica a la variable objetivo. El modelo final se define mediante la Ecuación 10:

$$\log(\hat{y}_t) = f_{base}(T_t, S_t) + f_{ruido}(X_t) \quad (10)$$

donde  $t$  es el tiempo,  $f_{base}$  representa al modelo base encargado de estimar la tendencia ( $T_t$ ) y la estacionalidad ( $S_t$ ), y  $f_{ruido}$  modela los residuos no lineales usando variables exógenas y de calendario ( $X_t$ ).

Para la capa de tendencia y estacionalidad, se generaron características de estacionalidad usando Series de Fourier. Se implementaron armónicos para capturas la estacionalidad anual y semanal. Debido a la alta dimensionalidad generada por los términos sinusoidales, se seleccionó el modelo de regresión lineal Elastic Net como algoritmo base, ya que combina penalizaciones Lasso (L1) y Ridge (L2) para evitar el sobreajuste.

Los residuos generados por la primera capa ( $y_t - \hat{y}_t$ ) se utilizaron como variable objetivo para la segunda capa. Se implementó el algoritmo XGB dada su capacidad para capturar interacciones no lineales complejas. En el enfoque univariado, los predictores de esta capa fueron variables de calendario (mes, día de la semana y variables indicadores de fin de semana y festivos en Colombia). En el enfoque multivariado, se incorporaron adicionalmente el volumen de los embalses y los aportes hidrológicos.

### *Optimización de Hiperparámetros y Validación Cruzada*

Con el fin de garantizar la capacidad de generalización de los modelos, se realizó una búsqueda de hiperparámetros mediante la técnica de Grid Search. En el modelo de Elastic Net, cuyos principales hiperparámetros son la fuerza del término de regularización ( $\alpha$ ), que impacta directamente en la complejidad del modelo y, la relación entre la regularización L1 y L2 (ratio l1). Diversos investigadores han trabajado con valores que oscilan entre 0.001 a 10 para  $\alpha$  y 0 a 1 para el ratio l1 (Jin et al., 2025; Rodriguez, 2025; Sleem & Syed, 2025). Por ello, se iteró una malla con los rangos mostrados en la Tabla 5 para este modelo.

**Tabla 5**

*Parámetros y Rangos Usados en la Validación de Hiperparámetros de Elastic Net*

Parámetro	Valores usados
alpha	[0.001, 0.01, 0.05, 0.1, 0.5, 1, 5, 10]
l1_ratio	[0.01, 0.1, 0.5, 0.7, 0.9, 1]

*Nota.* Intervalos basados en investigaciones de múltiples autores (Jin et al., 2025; Rodriguez, 2025; Sleem & Syed, 2025).

Por su parte, en el modelo XGB, los hiperparámetros de mayor relevancia son la cantidad de árboles usados (`n_estimators`), la tasa de aprendizaje de cada árbol (`learning_rate`), la profundidad máxima de cada árbol (`max_depth`), el poder de regularización (`reg_alpha`), la cantidad de muestras que evalúa cada árbol (`subsample`), la cantidad de columnas que evalúa cada árbol (`colsample_bytree`), la pérdida mínima de error requerida para realizar una nueva partición de datos (`gamma`) y el peso mínimo para formar un nodo hijo (`min_child_weight`) (Deepika & Pandove, 2025; Hussain et al., 2025; Mehdary et al., 2024; Rodriguez, 2025). Los

hiperparámetros e intervalos usados para el proceso de Grid Search del modelo XGB se exhiben en la Tabla 6.

**Tabla 6**

*Parámetros y Rangos Usados en la Validación de Hiperparámetros de XGB*

Parámetro	Valores usados
n_estimators	[50, 100, 250, 350, 500]
learning_rate	[0.001, 0.01, 0.1]
max_depth	[3, 5, 7]
subsample	[0.6, 0.8, 1]
colsample_bytree	[0.6, 0.8, 1]
min_child_weight	[1, 3, 5]
reg_alpha	[0.1, 1]
gamma	[0, 0.1, 0.5]

*Nota.* Intervalos basados en (Deepika & Pandove, 2025; Hussain et al., 2025; Mehdary et al., 2024; Rodriguez, 2025).

Finalmente, la selección de los mejores hiperparámetros de Prophet. Diversas investigaciones usan valores de `changepoint_prior_scale` y `seasonality_prior_scale` que van de 0.001 a 100, `n_changepoint` de 1 a 60 y ambos valores de `seasonality_mode` (Adha et al., 2026; Alhaj Omar & Pamuk, 2026; Bello et al., 2026; Zherlitsyn et al., 2025). Fueron optimizados los parámetros, entre los posibles valores de la Tabla 7.

**Tabla 7**

*Parámetros y Rangos Usados en la Validación de Hiperparámetros de Prophet*

Parámetro	Valores usados
changeoint_prior_scale	[0.05, 0.1, 0.5, 1, 10]
seasonality_prior_scale	[0.05, 0.1, 0.5, 1, 10]
seasonality_mode	["additive", "multiplicative"]
n_changeoints	[10, 25, 50]

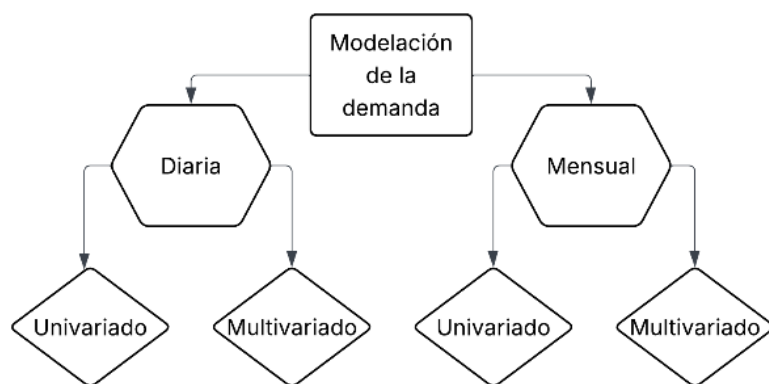
*Nota.* Intervalos con base en (Adha et al., 2026; Alhaj Omar & Pamuk, 2026; Bello et al., 2026; Zherlitsyn et al., 2025).

### ***Evaluación, Intervalos de Predicción y Extrapolación***

El desempeño de los modelos en el conjunto de validación (2025) se evaluó revirtiendo la transformación logarítmica mediante la función exponencial, y tomando en cuenta los enfoques univariado y multivariado y la resolución diaria y mensual (**Figura 1**).

**Figura 1**

*Esquema de Modelación de la Demanda*



Se utilizaron tres métricas para evaluar el desempeño predictivo: el RMSE, el MAPE y el MASE. El MASE fue calculado utilizando un pronóstico ingenuo estacional (7 días para escala diaria y 12 meses para escala mensual) sobre el conjunto de entrenamiento. Dado que los algoritmos de ML generan pronósticos puntuales y carecen de estimaciones probabilísticas de manera nativa, la incertidumbre se cuantificó a partir de la distribución de los errores del modelo. En concreto, el margen de error fue definido mediante el cálculo del percentil 95 de los residuos absolutos del conjunto de validación. Este enfoque fue seleccionado por encima del método tradicional de multiplicar el valor  $Z$  asociado al 95% ( $Z = 1.96$ ) por la desviación estándar ya que este asume que los residuos tienen normalidad y, en la realidad las series de tiempo suelen presentar valores atípicos y varianzas irregulares. Rayer et al. (2009) afirman que la ventaja de usar percentiles es que el cálculo se puede acomodar a cualquier tipo de distribución de los errores.

De la misma manera, obtener los límites del intervalo directamente de los cuantiles evita incorporar supuestos sobre los datos y otorga una estimación más robusta y realista para medir la incertidumbre del pronóstico (Nguinabé et al., 2025; Welagedara et al., 2026) y finalmente, se procedió a realizar una extrapolación para el periodo comprendido entre 2026 y 2029. Cabe resaltar que este procedimiento de largo plazo no fue replicado para el enfoque multivariado, puesto que requería disponer de proyecciones precisas del volumen de los embalses y los aportes hidrológicos para dicho horizonte futuro.

### **Fase 3 Diseño de la Solución y Encapsulamiento**

#### ***Arquitectura del Pipeline de Datos***

Con el propósito de garantizar reproducibilidad de los resultados y de la investigación, se diseñó un Pipeline analítico. Consiste en un diseño modular que permite ejecutar de forma

automatizada todo el ciclo de vida de los datos, aislando los procesos en tres componentes principales: módulo de descarga (conexión a la API de XM y lectura del archivo de la UPME para comparación de proyecciones), el módulos de preprocesamiento (ingeniería de características, codificación de variables de calendario, transformaciones de Fourier y modelado con híbrido/Prophet) y el módulo de evaluación (comparación de métricas de los modelos, selección del mejor modelo, comparación con proyecciones de la UPME y exportación de pronósticos del mejor modelo). Todos los modelos fueron exportados al formato JOBLIB y JSON, permitiendo su almacenamiento y posterior carga sin necesidad de repetir la fase computacional del entrenamiento y la optimización de hiperparámetros.

### ***Estrategia del Encapsulamiento***

Se estructuró bajo un enfoque de procesamiento por lotes. A través de este mecanismo, el sistema toma los datos históricos más recientes y las proyecciones de las variables exógenas para generar las estimaciones de la demanda eléctrica en el horizonte indicado. Los resultados del modelo, incluidas las estimaciones puntuales y los límites inferior y superior de los intervalos de predicción al 95%, son exportados y consolidados en formato estructurado (CSV) para facilitar su visualización, análisis comparativo y toma de decisiones por parte de los actores del mercado energético.

### ***Consideraciones de Uso, Limitaciones y Mantenimiento***

Finalmente, se documentaron las implicaciones prácticas del sistema, entre las cuales se tiene la relevancia de instalar las versiones indicadas de cada librería y dependencia de los datos en formato tabular de la demanda de energía, los aportes hidrológicos y el volumen de los embalses directamente desde la API de XM. Este paso es clave para ahorrar tiempo en la recolección de datos y está sustentado en el mantenimiento y disponibilidad de esta. Por ello,

tanto los conjuntos de datos como los modelos fueron almacenados localmente para garantizar la reproducibilidad. Otra consideración establecida recae sobre la precisión de los modelos multivariados, ya que está estrictamente condicionada a la disponibilidad de los datos futuros de aportes hidrológicos y volumen de embalses. Así mismo, dado el carácter dinámico del mercado eléctrico y los posibles cambios estructurales en la demanda, se requiere reentrenar periódicamente los modelos incorporando los datos más recientes para garantizar que los algoritmos adapten sus pesos a los patrones de comportamiento contemporáneos.

## Resultados

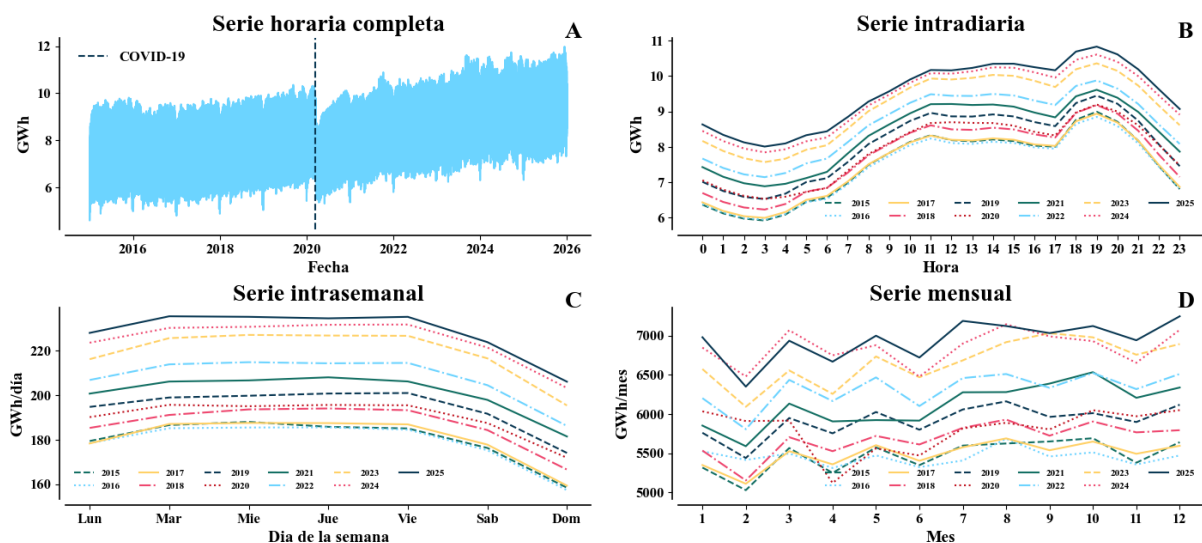
### Análisis Exploratorio de Datos (EDA)

#### *Demanda de Energía Eléctrica*

Se evidencia que la demanda de energía en Colombia tiende al aumento (Figura 2A) y que alrededor de la pandemia, que según la resolución 385 del 2020, el 12 de marzo de dicho año se declaró la emergencia sanitaria por COVID-19 (República de Colombia, 2020), se presenta una contracción de la demanda, seguida de una fase de recuperación con una pendiente de crecimiento más pronunciada y una mayor volatilidad en comparación con el periodo prepandemia.

### Figura 2

#### *Demanda de Energía Eléctrica en Colombia en Múltiples Escalas – 2015 a 2025*



#### *Estacionalidad Horaria y Semanal*

Se observa un perfil horario (Figura 2B) con una forma consistente a lo largo de la década analizada. Durante cada día a lo largo de los años, se tienen picos de demanda entre las horas 18:00 y 21:00 y valles entre las horas 1:00 y 4:00. Según lo menciona XM, esto coincide

con los patrones generales de la sociedad, de dormir en la madrugada (menor demanda) y estar en los hogares durante la noche (mayor demanda) (XM SA ESP, s. f.-a). Así mismo, la escala intra-semanal (Figura 2C) tiene sus mayores valores de martes a jueves, y desde el viernes y durante el fin de semana se presentan disminuciones de la demanda. Dicho comportamiento podría estar asociado a las múltiples empresas e industrias que solo operan durante la semana pero, que en fin de semana su consumo se reduce notablemente (Asoenergía, 2020; Hinman & Hickey, 2009).

### ***Dinámica Mensual y Efectos Estacionales***

La escala mensual (Figura 2D) revela una oscilación bimensual durante el primer semestre de cada año, donde meses de 31 días (enero, marzo, mayo) presentan mayores valores respecto a sus sucesores inmediatos. No obstante, el hallazgo más relevante es que en el cuarto trimestre se presenta una caída reiterada en noviembre seguida de un incremento significativo en diciembre. Este fenómeno puede ser atribuido al componente cultural asociado al encendido de alumbrados navideños y el aumento de la actividad comercial a fin de año, que generan un pico estacional recurrente. Dichos comportamientos semanal y mensual justifican la implementación de términos sinusoidales para capturar tendencias de 7 días y 12 meses.

### ***Análisis Cuantitativo de la Demanda***

La Tabla 8 muestra las estadísticas descriptivas de la demanda desglosadas por ventana temporal anualmente. Se evidencia una progresión constante en el promedio de consumo; en la serie diaria, el promedio pasó de 180 GWh-día en 2015 a 228 GWh-día en 2025, lo que representa un incremento de 26.9% en la década analizada. Es fundamental destacar que, a pesar de los aumentos en la demanda máxima y promedio, la dispersión (DE) se ha mantenido relativamente estable en la serie horaria ( $\sim 0.9$  a 1 GWh), lo que sugiere que, si bien el sistema

demanda más energía, la forma del perfil de consumo conserva una estructura predecible. Se resalta que 2020 fue el único periodo donde la demanda promedio bajó en todas las escalas temporales respecto al año anterior. Esto cuantifica el impacto de las medidas ejecutadas durante la emergencia sanitaria del COVID-19.

**Tabla 8**

*Estadísticas Descriptivas de la Demanda Eléctrica Desglosadas por Año*

Año	Serie horaria				Serie intra-semanal				Serie mensual			
	Min	Prom	Max	DE	Min	Prom	Max	DE	Min	Prom	Max	DE
2015	5.9	7.5	9.0	1.0	158	180	188	10	5,028	5,471	5,691	205
2016	5.9	7.4	8.8	0.9	157	179	185	10	5,311	5,452	5,685	102
2017	6.0	7.5	8.9	0.9	159	181	187	10	5,110	5,490	5,689	162
2018	6.2	7.8	9.2	1.0	167	187	194	10	5,152	5,682	5,929	210
2019	6.5	8.1	9.4	1.0	174	194	201	10	5,438	5,911	6,161	199
2020	6.5	7.9	9.2	0.9	172	190	196	9	5,120	5,799	6,049	281
2021	6.9	8.4	9.6	0.9	181	201	208	9	5,589	6,111	6,533	274
2022	7.1	8.7	9.9	0.9	186	208	215	10	5,805	6,319	6,523	217
2023	7.6	9.1	10.4	1.0	195	219	227	12	6,092	6,661	7,030	288
2024	7.8	9.4	10.6	0.9	203	225	232	10	6,475	6,848	7,144	222
2025	8.0	9.5	10.8	0.9	206	228	235	11	6,349	6,941	7,246	253


*Nota.* PROM es el promedio y DE es la desviación estándar.

Al analizar la variación porcentual interanual (Figura 3), el sistema exhibe dos periodos de expansión acelerada: 2021 (5.39%) y 2023 (5.42%). El repunte de 2021 obedece al efecto

rebote postpandemia, que intenta compensar la contracción de -1.9% registrada en 2020. Por el contrario, el incremento significativo de 2023 no responde a un fenómeno de recuperación, sino a una expansión genuina de la demanda. Al excluir el año 2020 (considerado un valor atípico dentro de la serie temporal), la tasa de crecimiento promedio anual de la demanda eléctrica en Colombia se sitúa en 2.95%, consolidando la premisa de un sistema en expansión sostenida.

**Figura 3**

*Cambio Porcentual Anual de la Demanda Eléctrica*




### ***Población Nacional***

La evolución demográfica es un factor fundamental en la modelación de la demanda energética. De acuerdo con los datos consolidados del DANE, para 2018 la población nacional de Colombia fue aproximadamente 48.26 millones de habitantes. Y estimaron que, para 2025 llegaría a más de 53 millones de habitantes (DANE, 2021). Al evaluar el horizonte a largo plazo (Figura 4), las proyecciones del DANE sugieren que la población continuará expandiéndose hasta alcanzar un límite superior en el año 2043, con un pico proyectado alrededor de 56 millones de habitantes, lo cual supone a futuro un cambio en la demanda base del sistema.


## Figura 4

### *Población Actual y Proyectada hasta 2070*



### *Dinámica de Crecimiento Interanual a Corto Plazo*


En el horizonte temporal de análisis (2015-2025), la Figura 5 exhibe la población anual total y su respectiva variación porcentual respecto al año anterior. Entre 2016 y 2020 el crecimiento fue acelerado y sostenido hasta del 2.28% anual. A partir de 2021 se experimentó una desaceleración significativa que se estabilizó por debajo del 1% anual durante 3 años consecutivos. No obstante, a pesar de la reducción en el ritmo de crecimiento, la tasa de crecimiento se mantiene en 1.36%, lo cual implica la incorporación continua de cientos de miles nuevos usuarios a la red eléctrica. Esto explica en la expansión de la demanda eléctrica evidenciada en la sección anterior.

**Figura 5***Cambio Porcentual Anual de la Población****Producto Interno Bruto (PIB)***

El comportamiento de la macroeconomía colombiana, representado por el producto interno bruto (PIB), sirve como indicador de la actividad industrial y comercial del país, las cuales tienen implicación directa en la demanda de energía eléctrica. La Figura 6 compara la variación trimestral del PIB agregado y el PIB de la categoría “Generación de energía eléctrica; transmisión de energía eléctrica y distribución y comercialización de energía eléctrica”. Aunque ambas tienen una tendencia similar, el PIB del sector eléctrico presenta mayor volatilidad en el tiempo. De manera consistente con los hallazgos de la serie de la demanda de energía, el impacto de la pandemia se refleja en el quiebre profundo en los trimestres centrales de 2020.

**Figura 6**

*Variación Trimestral del PIB Total y del Sector Eléctrico*




### *Dinámica Trimestral Histórica*

Al desglosar la variación trimestral histórica (Figura 7), se observa que la economía de Colombia operó en márgenes relativamente estables (cerca del 0%) durante la mayor parte del periodo analizado. Las excepciones evidentes corresponden a los datos atípicos de 2020 y 2021, específicamente el segundo trimestre (T2) de 2020 registró el punto de contracción más severo de toda la serie temporal con un -16.3%, lo que cuantifica la paralización de las actividades productivas debido al confinamiento.

**Figura 7**

*Variación del PIB Trimestral Año a Año*




### *Análisis Comparativo Frente al Promedio Histórico*

Para evaluar el desempeño esperado a corto plazo aislando el ruido, se excluyeron 2020 y 2021 de promedio histórico. Al contrastar la variación trimestral del 2025 frente a dicha medida depurada (Figura 8), se evidencian diferencias estacionales marcadas. El primer y tercer trimestre (T1 y T3) de 2025 operan por encima de su promedio histórico con variaciones relativas de 17.65% y 173%.65%, respectivamente. En contraste, el segundo y cuarto trimestre (T2 y T4) se sitúan por debajo de su nivel histórico esperado (-44.83% y 80%). Este patrón alternante en picos reafirma el potencial de incorporar el PIB como variable exógena en modelos multivariados para capturar variaciones que la estacionalidad simple no logra explicar.

**Figura 8**

*Cambio Porcentual Trimestral del PIB*




### *Aportes Hidrológicos y Embalses Nacionales*

Dada la composición predominante de hidroeléctricas en la matriz energética de Colombia, las variables climáticas actúan como condicionantes del sistema. Las fases del fenómeno de El Niño-Oscilación del sur (ENSO) influyen directamente en la disponibilidad hídrica del país. Al contrastar históricamente los aportes hidrológicos diarios con el Índice del Niño Oceánico (ONI) (Figura 9), se evidencia una fuerte correlación inversa (Rudnick &

Velásquez, 2021). Durante las fases frías o fenómenos de La Niña (valores del ONI inferiores a -1), el sistema registra incrementos notables en los aportes hidrológicos. Por el contrario, durante las fases cálidas o El Niño (valores del ONI superiores a 1), evidenciados con alta intensidad en los años 2016 y 2024, los caudales entrantes al sistema sufrieron reducciones críticas.


**Figura 9**

*Aportes Hidrológicos vs ONI*




### ***Estacionalidad Hidrológica Interanual y Caso Atípico de 2025***

Respecto a la escala mensual, el régimen hidrológico de Colombia muestra un comportamiento bimodal. Las temporadas de mayores aportes (Figura 10) se concentran en abril y junio, y posteriormente entre octubre y noviembre. De manera similar, el sistema enfrenta dos periodos de “sequía” durante los meses de enero a marzo y de julio a septiembre.

**Figura 10***Aportes Hidrológicos Mensuales por Año*

Al aislar el año 2025 y contrastarlo contra el promedio histórico del periodo analizado (Figura 11), se aprecia un escenario hidrológico atípico. Todos los meses de 2025 superaron su respectiva media histórica. Particularmente, febrero registró casi el doble de lo esperado (96.37%). Este flujo hídrico elevado se mantuvo con tendencia al alza durante todo el año, con incrementos por encima del 24% respecto al histórico (excepto en noviembre).


**Figura 11***Aportes Hidrológicos de 2025 vs Promedio Histórico*

### *Dinámica del Volumen de los Embalses*

El volumen de los embalses funciona como la variable de acumulación del sistema y responde con una dinámica similar a los aportes, aunque con un leve rezago temporal (Figura 12). Durante el extenso periodo de 2020 a 2023, caracterizado por valores negativos del ONI (La Niña), el país mantuvo los niveles de embalsamiento por encima del 50% incluso en los puntos más bajos. En contraste, la severa transición hacia la fase de El Niño entre 2023 y 2024 redujo las reservas, llevando los embalses a niveles críticos alrededor del 30% de su capacidad útil a principios del 2024.

### **Figura 12**

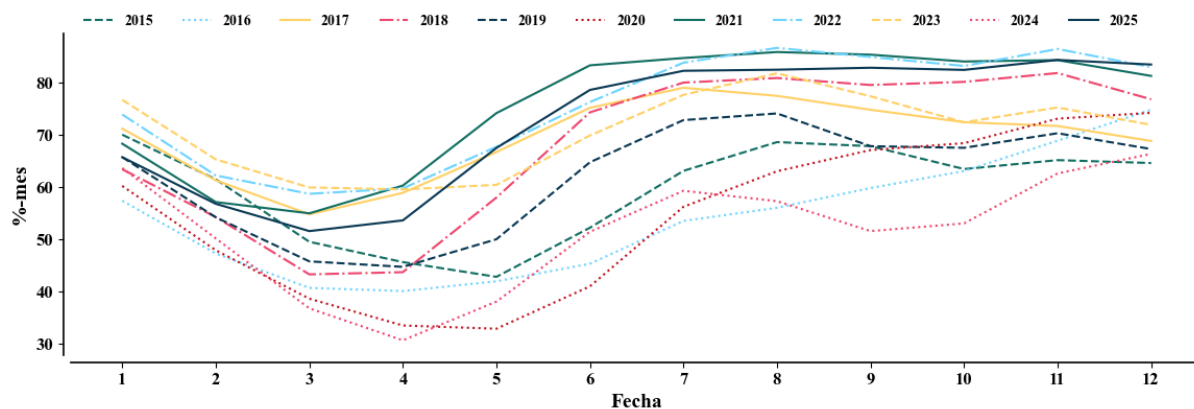
#### *Volumen Promedio de los Embalses vs ONI*



A diferencia de los aportes, el volumen de los embalses solo presenta un valle (marzo a mayo), seguido de una fase de recarga que culmina en una estabilización o “meseta” de altos niveles de embalsamiento que se sostiene de junio a diciembre (Figura 13).

**Figura 13**


*Volumen Promedio de los Embalses por Año*



Finalmente, el comportamiento en 2025 (Figura 14) refleja la recuperación del sistema tras el déficit hídrico de 2024 ocasionado por El Niño. Gracias al impulso de los aportes atípicos de este año, los embalses se mantuvieron por encima del promedio histórico con aumentos que oscilaron entre 12.46% y 26.7% entre abril y diciembre.

**Figura 14**

*Volumen Promedio de los Embalses en 2025 vs Promedio Histórico*

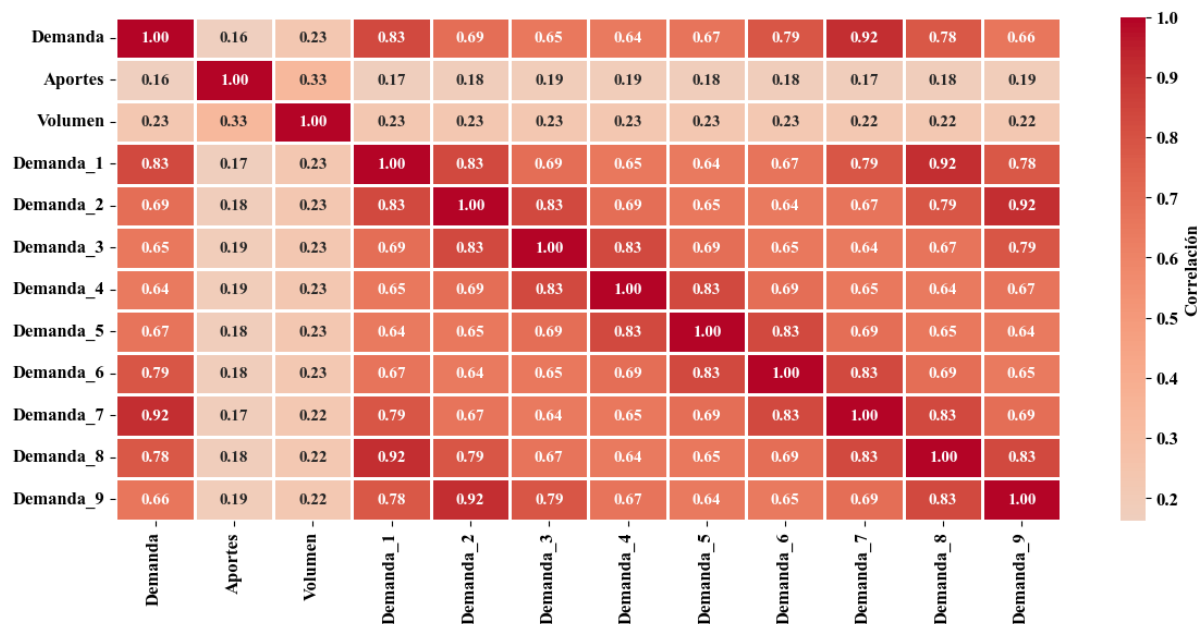


### *Análisis de Correlación Cruzada*

Al evaluar la matriz de correlación en la escala diaria (Figura 15) se observa que la relación cruzada entre la demanda con los aportes y el volumen de los embalses es débil ( $r_s = 0.16$  y  $r_s = 0.23$ , respectivamente). Sin embargo, hay un hallazgo significativo que radica en la autocorrelación de la demanda entre su valor actual y su primer rezago (Demanda\_1) de  $r_s = 0.83$  y llega a una magnitud de muy fuerte al ( $r_s = 0.92$ ) cruzarse con su séptimo rezago (Demanda\_7) y esto es coherente con el perfil descrito durante el análisis univariado. Además, esta correlación sirve como soporte para que el modelo ingenuo sea más robusto y sirva como comparación con los modelos utilizados.

**Figura 15**

*Correlación entre Demanda, Aportes y Volumen en Escala Diaria*

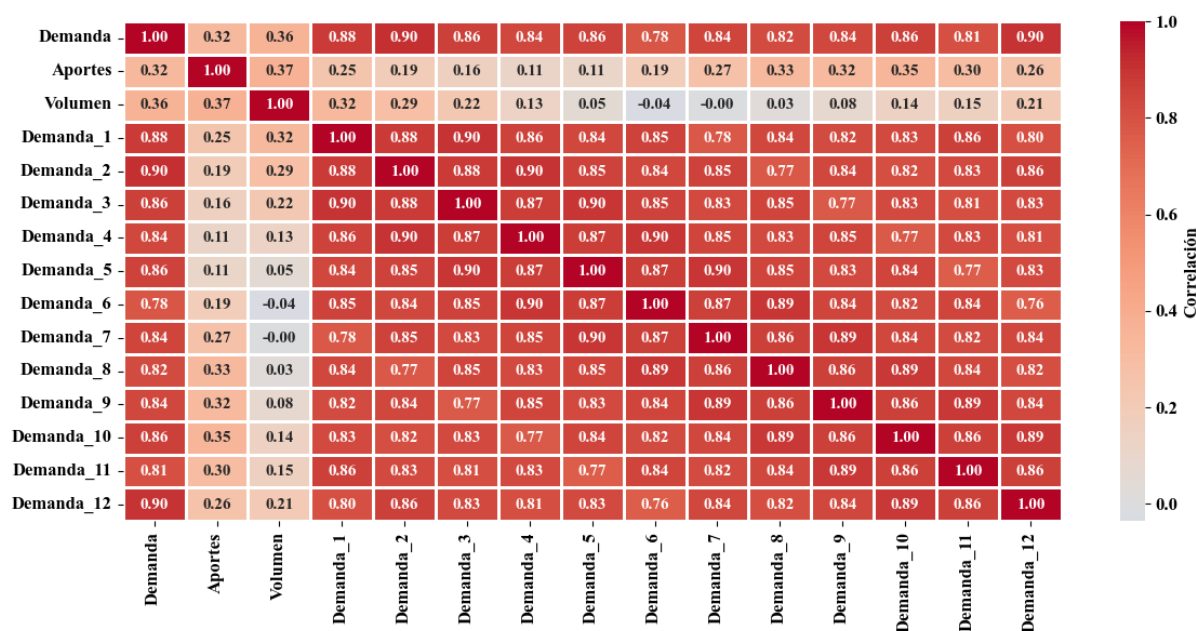


No obstante, al pasar a la escala mensual (Figura 16), el ruido de los efectos semanales se difumina, lo cual permita que se destaquen las relaciones macro. Ahora la correlación de la

demanda frente a los aportes ( $r_s = 0.32$ ) y al volumen ( $r_s = 0.36$ ) aumenta y se aproxima a umbrales de una correlación moderada. Este incremento en la relación estadística justifica la pertinencia de incluir estas dos variables exógenas como predictores dentro del proceso de modelación, bajo la hipótesis de que aportarán un mayor poder predictivo en escala mensual que en escalas de corto plazo (diarias).

**Figura 16**

*Correlación entre Demanda, Aportes y Volumen en Escala Mensual*

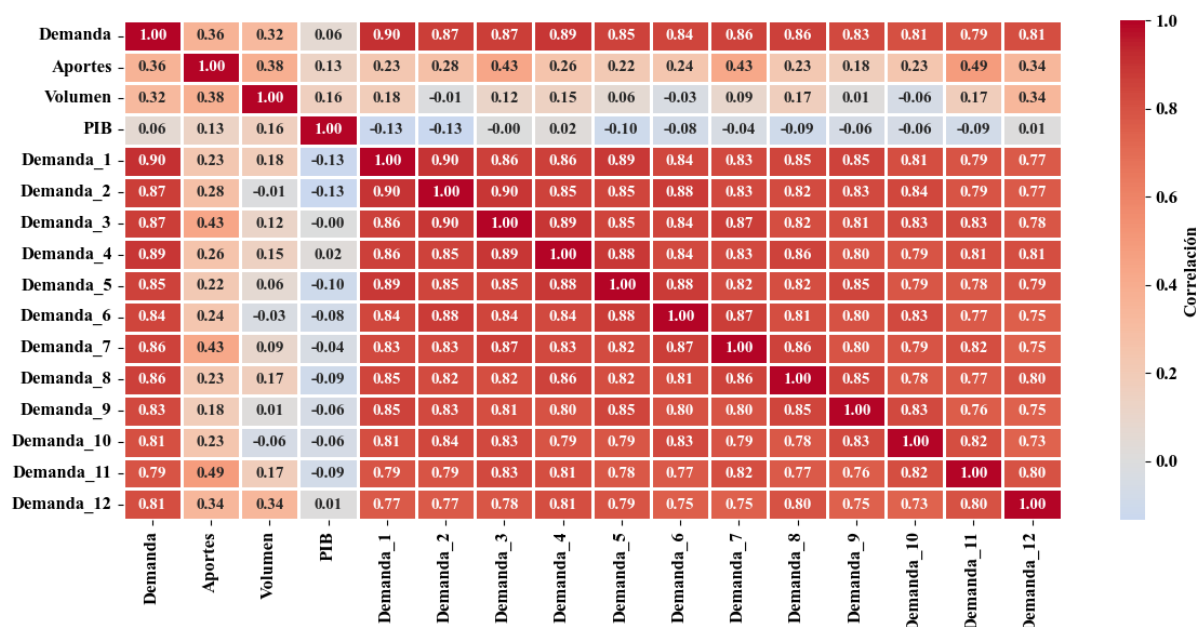


Al expandir la ventana de agregación, ya es posible incorporar el PIB en el análisis cruzado (Figura 17). En esta resolución escala, se mantienen las asociaciones entre la demanda y las variables hidrológicas (aportes y volumen) en magnitudes próximas al umbral de correlación moderada ( $r_s = 0.36$  y  $r_s = 0.33$ , respectivamente). No obstante, el coeficiente entre el PIB y la demanda resulta estadísticamente despreciable ( $r_s = 0.06$ ). Esto sugiere que, a corto y mediano

plazo, las variaciones del ciclo económico no representan un efecto lineal significativo con la estacionalidad de la demanda eléctrica.

**Figura 17**

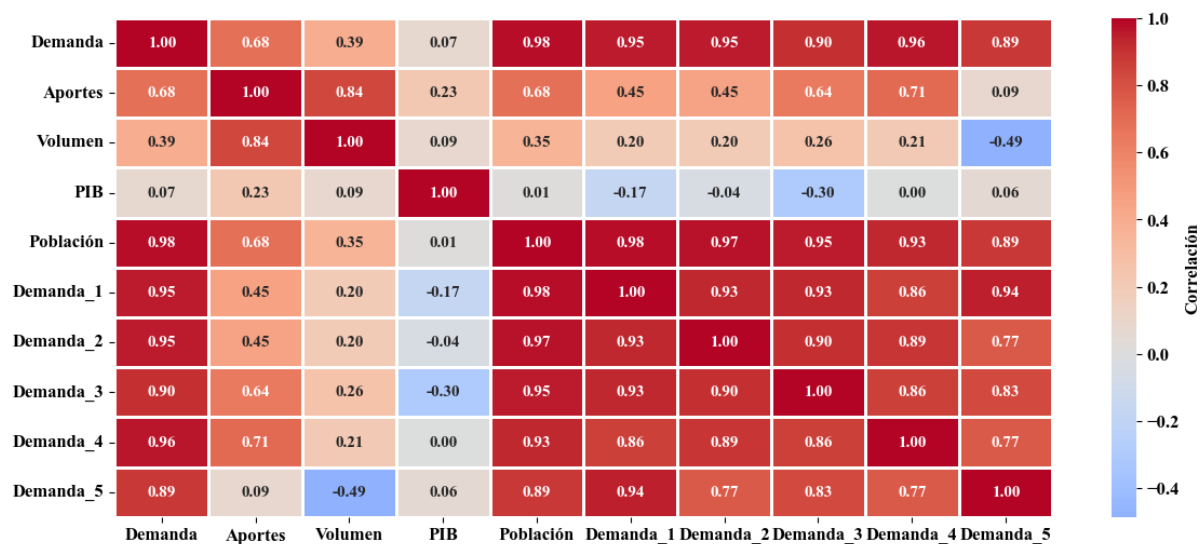
*Correlación entre Demanda, Aportes, Volumen y PIB en Escala Trimestral*



Finalmente, al evaluar la matriz en la escala anual (Figura 18), una vez más se suprime el ruido estacional y se incorpora la población como una variable. En esta resolución, se evidencia correlación muy fuerte entre la demanda y la población ( $r_s = 0.98$ ), confirmando matemáticamente la hipótesis sobre el impacto directo de la expansión sostenida de usuarios en la presión sobre el sistema eléctrico. Además, la demanda y sus rezagos ahora tienen correlaciones moderada y fuerte con los aportes (alcanzando hasta  $r_s = 0.71$ ).

**Figura 18**

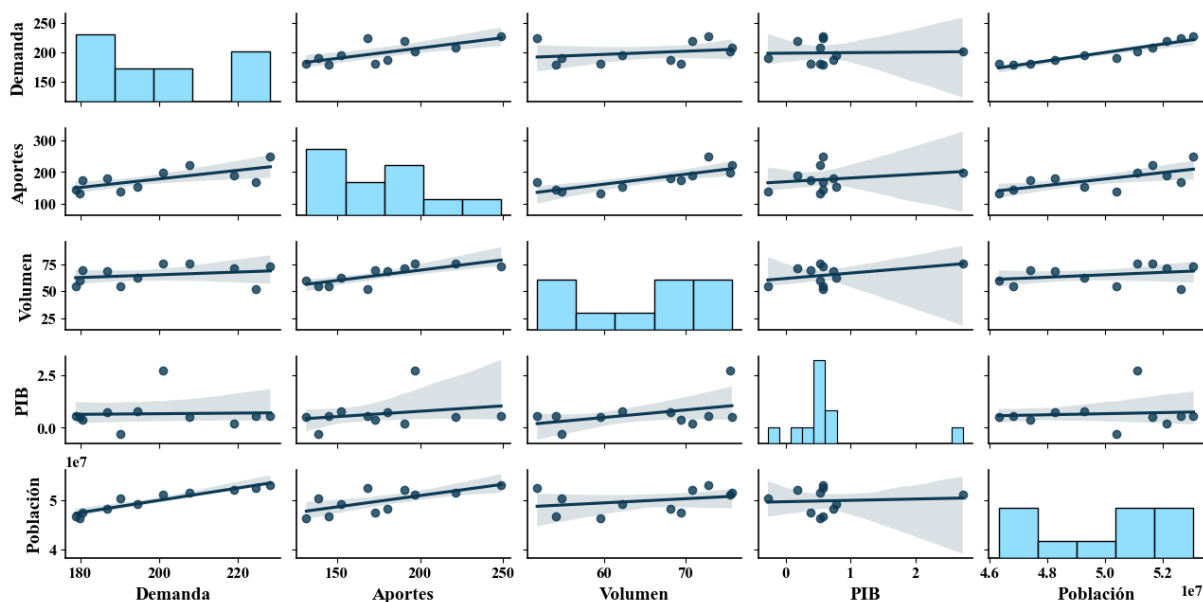
*Correlación entre Demanda, Aportes, Volumen, PIB y Población en Escala Anual*



Cabe resaltar, que en esta escala el volumen tiene relación inversamente proporcional con la demanda rezagada cinco años ( $r_s = -0.49$ ). Desde una perspectiva operativa y climática, esto indica que los valores altos de embalsamiento en un año base (por ejemplo, asociados a un fenómeno de La Niña) tendieron a asociarse con niveles más bajos de la demanda cinco años en el futuro. Esto refleja la compleja interacción entre los ciclos hidrológicos extendidos y los cambios en la demanda.

Para complementar el cálculo de los coeficientes de correlación, se generó una matriz de dispersión con ajustes de regresión lineal para las variables agregadas en escala anual, excluyendo los rezagos temporales (Figura 19). En ella se confirma la linealidad y la fuerza de relación entre la demanda de energía anual y la expansión demográfica (población), así como la tendencia positiva frente a los aportes hidrológicos.

Figura 19

*Análisis Multivariado en Escala Anual*

Con base en los hallazgos descriptivos consolidados, se evidencia que los aportes, el volumen de los embalses y población son candidatos ideales como predictores exógenos. Sin embargo, dicha relación solo se presenta en la escala anual, en la cual apenas se cuenta con una muestra reducida de aproximadamente 11 datos, lo cual hace inviable estadísticamente un proceso robusto de modelación con algoritmos complejos de Machine Learning sin llegar a un sobreajuste severo.

Por otra parte, el PIB no se demostró una asociación lineal consistente con la demanda en ninguna de las escalas con la demanda o alguno de sus rezagos. En consecuencia, se determinó que la etapa de modelación predictiva se ejecutará exclusivamente en las escalas diaria y mensual incorporando únicamente a los aportes y al volumen de los embalses como variables exógenas para los enfoques multivariados.


## Evaluación y Comparación de Modelos

### *Modelación Diaria Univariada*


Para el entrenamiento del modelo híbrido univariado en la escala diaria, se usó una ventana histórica con 3653 observaciones, correspondientes al periodo comprendido entre el 1 de enero 2015 y el 31 de diciembre de 2024 de datos. Y para la etapa de validación se tuvieron 365 datos, correspondientes a todo 2025 (esto aplica en todos los casos de la escala diaria). Tal como se definió en la arquitectura de la Fase 2, la capa base de regresión integró variables temporales auxiliares (mes, día de la semana e indicadores binarios para fines de semana y festivos) con el objetivo de modelar las caídas cíclicas de la demanda (Hinman & Hickey, 2009), así como transformaciones sinusoidales para capturar la estacionalidad compleja (Bansal et al., 2025).

El desempeño predictivo del modelo sobre el conjunto de validación arrojó métricas satisfactorias: un RSME de 5.78 GWh-día, un MAPE de 2.1% y un MASE de 0.85. En términos prácticos, esto indica que el modelo logró predecir la demanda con una desviación promedio inferior al 3% diario. Cabe resaltar que el MASE al ser menor a 1, demuestra que el ensamble híbrido superó el desempeño del pronóstico ingenuo estacional (basado en el séptimo rezago), confirmando la ganancia del enfoque propuesto.

La Figura 20 se muestra la reconstrucción de este proceso, contrastando la serie histórica, los valores reales frente a los pronosticados para 2025, y la extrapolación generada hasta 2029. Se aprecia que el algoritmo logra capturar los valles que típicamente se presentan al comienzo de cada año y la volatilidad diaria de la serie. Al proyectar la tendencia, se estima que el sistema eléctrico colombiano enfrentará picos máximos cercanos a los 270 GWh-día para el cierre de 2029.

**Figura 20***Proyección de la Demanda Eléctrica Diaria Univariada con Modelo Híbrido*

En cuanto a la estimación de la incertidumbre, el cálculo basado en los residuos empíricos de validación permitió establecer intervalos de predicción al 95% de confianza con un margen de  $\pm 10.9$  GWh-día alrededor del valor pronosticado. Esto se con mayor detalle para el periodo de validación (2025) en la Figura 21, la cual exhibe que las estimaciones generalmente capturan los valles, pero les cuesta capturar completamente los picos. Además, se obtuvo que, bajo condiciones operativas normales, para el día de máxima exigencia proyectado (5 de diciembre de 2029), el consumo oscilará dentro de una banda acotada que va de los 259.9 a los 281.7 GWh-día.


**Figura 21***Validación Demanda Eléctrica Diaria Univariada con Modelo Híbrido 2025*

Por otro lado, se evaluó el desempeño del modelo Prophet bajo el mismo enfoque univariado. Los resultados obtenidos sobre el conjunto de validación de 2025 arrojaron un RMSE de 7.4 GWh-día, un MAPE de 2.6% y un MASE = 1.0. Este modelo no logra superar el umbral del modelo ingenuo ( $MASE > 1$ ), y su precisión general es inferior a la obtenida en la arquitectura híbrida. Esta diferencia de rendimiento sugiere que el modelo aditivo Prophet presenta mayores limitaciones para capturar la complejidad en comparación con los algoritmos basados en ensamble (Gradient Boosting).

La Figura 22 exhibe la reconstrucción histórica, la etapa de validación y las proyecciones a largo plazo generadas por Prophet. Visualmente, el modelo logra trazar la tendencia de crecimiento. Al extrapolar la serie hacia 2029, el comportamiento de la tendencia es consistente con el del modelo híbrido. Para los escenarios de mayor exigencia, se espera que la demanda diaria oscile en un rango comprendido entre 266.9 y 295.2 GWh-día el 6 de diciembre de 2029.

## Figura 22

### *Proyección de la Demanda Eléctrica Diaria Univariada con Modelo Prophet*




Respecto a la incertidumbre, se obtuvieron intervalos de predicción al 95% de confianza con un margen de  $\pm 14.2$  GWh-día alrededor de cada valor pronosticado. Esto es detallado durante el periodo de validación (2025) en la Figura 23. A diferencia de la arquitectura híbrida

que destacó capturando los valles, Prophet no captura valles ni picos, y parece que una parte del tiempo sobrestima la demanda.

### Figura 23


#### *Validación Demanda Eléctrica Diaria Univariada con Prophet 2025*




#### *Modelación Diaria Multivariada*

Al incorporar los aportes hidrológicos y el volumen de los embalses como variables exógenas, las métricas del modelo híbrido tuvieron una leve penalización. Esta vez se obtuvo un RMSE de 6.14 GWh-día; MAPE = 2.2% y MASE = 0.89. Si bien el algoritmo mantiene una capacidad predictiva válida ( $MASE < 1$ ), el enfoque univariado lo superó por un margen de 0.35 GWh al día en promedio. Esta degradación en el desempeño sugiere que en una escala temporal tan volátil (diaria), las variables hidrológicas inyectan ruido en lugar de aportar una señal predictiva clara.

La Figura 24 exhibe el ajuste del modelo multivariado durante la etapa de entrenamiento y de validación. A diferencia del enfoque univariado, no fue realizada la proyección hasta 2029 debido a dos factores: el menor desempeño predictivo ya evidenciado y el alto grado de incertidumbre estocástica que implicaría proyectar los aportes hidrológicos y el volumen de los embalses a varios años hacia el futuro.

**Figura 24***Proyección de la Demanda Eléctrica Diaria Multivariada con Modelo Híbrido*

Finalmente, respecto a la estimación de incertidumbre temporal, la amplitud del intervalo de predicción al 95% de confianza se expandió a  $\pm 11.6$  GWh-día (en contraste con los  $\pm 10.9$  GWh-día del univariado). Bajo este enfoque, las estimaciones para el escenario de mayor exigencia del periodo de validación (3 de diciembre de 2025) oscilan en una banda más amplia, proyectando una demanda diaria entre 230.8 y 253.9 GWh-día (Figura 25).


**Figura 25***Validación Demanda Eléctrica Diaria Multivariada con Modelo Híbrido 2025*

Al replicar el panorama multivariado utilizando Prophet, se evidenció una degradación todavía mayor en las estimaciones. Las métricas sobre el conjunto de validación reportaron un

RMSE de 10.3 GWh-día, un MAPE = 3.9% y MASE = 1.54. A pesar de tener métricas cercanas al modelo híbrido, su  $MASE > 1$  invalida la utilidad del algoritmo y permite inferir que sería más efectivo usar un pronóstico ingenuo que todo el esfuerzo computacional asociado a este enfoque de modelación. La Figura 26 ilustra el comportamiento de este enfoque. Visualmente se percibe una sobre estimación en la etapa de validación (la banda de predicción naranjada se sitúa por encima de los valores reales la mayor parte del tiempo).

## Figura 26


### *Proyección de la Demanda Eléctrica Diaria Multivariada con Prophet*



Así mismo, la inclusión de variables exógenas aumento la incertidumbre de los intervalos de predicción. Según los resultados del modelo, las estimaciones del intervalo de predicción al 95% de confianza, se tiene que las estimaciones se oscilan entre  $\pm 19.0$  del valor estimado y se tiene que la demanda de energía proyectada es 257.5 GWh-día para el periodo más lejano de la etapa de validación, correspondiente al 11 de diciembre de 2025 (Figura 27).

## Figura 27

### *Validación Demanda Eléctrica Diaria Multivariada con Prophet 2025*



### *Limitación de la Extrapolación Multivariada*

La incapacidad de generar pronósticos hacia el horizonte 2026-2029 con los enfoques multivariados, radica en la dependencia estricta de las variables exógenas de entrada. Para que el algoritmo (tanto el híbrido como Prophet) pueda inferir la demanda futura, requiere conocer los valores futuros de los aportes hidrológicos y el volumen de los embalses. Para generar dichos vectores, se necesitaría desarrollar modelos de pronóstico climático en paralelo lo cual a su vez desencadena un desafío de propagación de error que puede deteriorar las métricas todavía más. Esta limitación de diseño operativo reafirma, de manera concluyente, la superioridad y viabilidad del enfoque univariado híbrido (Elastic Net – XGB) diario para la planeación energética a largo plazo (Barrientos et al., 2023; Lee et al., 2022; Velásquez et al., 2009).


### *Modelación Mensual Univariada*

Al escalar la ventana de agregación temporal a una resolución temporal mensual, se produce un suavizado en la serie (asociado al ruido diario y el efecto puntual de los festivos y fines de semana). Esta reducción del ruido permite que la arquitectura híbrida capture la tendencia con mayor precisión. La Figura 28 ilustra el desempeño predictivo del enfoque híbrido

univariado sobre esta escala. La evaluación sobre el periodo 2025 arrojó métricas de errores sobresalientes: un RMSE de 92.2 GWh-mes, un MAPE del 1.1% y un MASE de 0.33. Este último indicador es contundente y demuestra que el algoritmo híbrido reduce el error un 67% en comparación con el pronóstico ingenuo de 12 meses.

## Figura 28

*Proyección de la Demanda Eléctrica Mensual Univariada con Modelo Híbrido*




En términos operativos, un MAPE del 1.1% indica un nivel de incertidumbre mínimo para la planeación energética a mediano y largo plazo. Al extrapolar la serie bajo este modelo hacia el horizonte 2026-2029, se proyecta una expansión sostenida que alcanzará su pico máximo de demanda en agosto de 2029, con un valor estimado de 7,945 GWh-mes. Para validar la consistencia interna de los modelos, al desagregar al valor mensual a una métrica diaria promedio, el resultado es de aproximadamente 256.3 GWh-día, un valor que se encuentre perfectamente alineado dentro del intervalo de predicción estimado por el modelo diario (que estimó un pico diario de 281.7 GWh-día).

Respecto a la estimación de la incertidumbre, el modelo acotó el intervalo de predicción al 95% de confianza con un margen de  $\pm 158.9$  GWh-mes alrededor de cada estimación puntual (Figura 29). Esta franja es mucho más estrecha y estable que la obtenida en la resolución diaria,

reafirmando que la agregación mensual es óptima para proyecciones de largo plazo en el sistema eléctrico de Colombia.

## Figura 29


### *Validación Demanda Eléctrica Mensual Univariada con Modelo Híbrido 2025*



Esta vez hubo diferencias notables con el enfoque de Prophet respecto al modelo híbrido. Las métricas sobre el conjunto de validación de 2025 registraron un RMSE de 202.6 GWh-mes, un MAPE de 2.7% y un MASE =0.8. Aunque el MASE es inferior a 1 confirma que Prophet mantiene una precisión superior al pronóstico ingenuo mensual, su desempeño general resulta inferior al del enfoque híbrido (cuyo RMSE fue 92.2 GWh-mes que es menos de la mitad que Prophet). Esto reafirma que el ensamble con Elastic Net y XGB gestiona de mejor manera el ruido de la demanda, incluso al trabajar con una serie suavizada temporalmente. Prophet proyecta que para 2026-2029 la demanda continuará expandiéndose, alcanzando valores máximos de 8453 GWh-mes en octubre de 2029, equivalente a un promedio operativo de 273 GWh-día (Figura 30).

**Figura 30**


*Proyección de la Demanda Eléctrica Mensual Univariada con Modelo Prophet*



Al analizar la estimación de la incertidumbre estadística a largo plazo, Prophet vuelve a quedarse atrás frente al modelo híbrido con un intervalo de predicción al 95% de  $\pm 288.6$  GWh-mes respecto al  $\pm 158.9$  GWh-mes del híbrido. En la escala mensual se conserva el comportamiento de Prophet a sobrestimar la demanda ya que en todos los meses a excepción del primero estimó valores por encima de lo real (Figura 31). Esta diferencia implica que el algoritmo aditivo puro genera proyecciones con un 82% más de incertidumbre. En consecuencia, el modelo híbrido se consolida como el más preciso y estable para la planeación energética a mediano plazo.

**Figura 31**

*Validación Demanda Eléctrica Mensual Univariada con Prophet 2025*




### ***Modelación Mensual Multivariada***

De manera similar a lo sucedido en la escala diaria, la incorporación de variables exógenas en la escala mensual no se tradujo en ganancia de información útil para el algoritmo. Las métricas de desempeño sobre el conjunto de validación registraron un RMSE de 109 GWh-mes, un MAPE = 1.23% y un MASE de 0.36. Si bien estas métricas confirman que el algoritmo mantiene una alta robustez (superando el pronóstico ingenuo, al tener un MASE<1), evidencian una degradación de desempeño frente a su homólogo univariado (cuyo RMSE fue de 92.2 GWh-mes y MAPE de 1.1%). Este resultado reafirma que, para el sistema eléctrico colombiano, la serie histórica de la demanda tiene un comportamiento que permite proyecciones de sí misma incluso sin la adición de variables exógenas (Figura 32). En consecuencia, y respetando las restricciones metodológicas expuestas para el modelo diario, no se ejecutó una extrapolación para el periodo 2026-2029. La alta incertidumbre asociada a la estimación de variables climáticas futuras (aportes hidrológicos y niveles de embalses) haría inviable una proyección confiable con este modelo.

### **Figura 32**


#### *Proyección de la Demanda Eléctrica Mensual Multivariada con Modelo Híbrido*



Respecto a la franja de predicción, esta se expandió a  $\pm 197.3$  GWh-mes (superior respecto a los  $\pm 158.9$  GWh-mes del enfoque univariado). Bajo este escenario, el modelo estimó un pico de consumo para agosto de 2025 de 6901 GWh-mes (Figura 33), que al desagregarse equivale a una demanda de aproximadamente 223 GWh-día.

**Figura 33**


*Validación Demanda Eléctrica Mensual Multivariada con Modelo Híbrido 2025*



Al evaluar el desempeño del modelo Prophet incorporando las variables exógenas, se evidenció una dinámica consistente con los resultados anteriores. Las métricas calculadas arrojaron un RMSE de 236.2 GWh-mes, un MAPE del 3.1% y un MASE de 0.9. A pesar de que estos valores representan una mejora respecto a la versión diaria de Prophet, su desempeño general continúa siendo inferior al de la arquitectura híbrida multivariada (cuyo RMSE fue de 109 GWh-mes). La Figura 34 ilustra el comportamiento de este enfoque.

**Figura 34**


*Proyección de la Demanda Eléctrica Mensual Multivariada con Modelo Prophet*



El modelo arrojó un margen de intervalo de predicción al 95% de confianza de  $\pm 348.2$  GWh-mes, convirtiéndose en la banda de incertidumbre más amplia de todos los enfoques evaluados en la escala mensual. Para el cierre de su periodo de validación, el modelo estimó que el pico sucede en octubre de 2025, donde la demanda esperada osciló entre 7120 GWh-mes y 7817 GWh-mes, equivalentes a un rango que va de 229 a 252 GWh-día (Figura 35).

**Figura 35**

*Validación Demanda Eléctrica Mensual Multivariada con Prophet 2025*




### *Selección del Modelo Óptimo*

Tras finalizar la evaluación de los enfoques algorítmicos (híbrido vs Prophet) y las dimensionalidades de entrada (univariado vs multivariado), en ambas resoluciones temporales. Se concluye que el modelo híbrido (Elastic Net y XGB) es escala mensual es el sistema óptimo con las mejores métricas de error y los intervalos de predicción más acotados, además de que elimina la dependencia de proyectar variables climáticas de largo plazo, lo cual lo vuelve la arquitectura que será encapsulada y desplegada en la Fase 3 del proyecto.

Para sintetizar los hallazgos en la modelación, la Figura 36 contrasta las métricas de error (RMSE, MAPE y MASE) para todas las configuraciones evaluadas en la resolución diaria. Se reafirman dos hipótesis de la investigación: en primer lugar, la superioridad del modelo híbrido frente al modelo Prophet en todos los escenarios; y en segundo lugar, la validación empírica de que el enfoque univariado genera resultados más precisos que su contraparte multivariada. En consecuencia, la arquitectura híbrida univariada se consolida como el diseño óptimo para la estimación diaria de la demanda de energía en Colombia.

**Figura 36**


#### *Métricas de Error en Escala Diaria*



De manera análoga, la Figura 37 consolida el desempeño predictivo para la resolución mensual. Se evidencia que, aunque el suavizado asociado a la agregación de los datos a una resolución temporal más gruesa beneficia el rendimiento, la jerarquía se mantiene intacta. La arquitectura híbrida domina sobre Prophet en todas las métricas evaluadas, y una vez más la dimensionalidad univariada supera a las configuraciones multivariadas. El modelo híbrido univariado se consolida como la herramienta óptima para la planificación mensual de la demanda de energía a mediano y largo plazo en Colombia.

**Figura 37**

*Métricas de Error en Escala Mensual*



***Validación Frente a Proyecciones Oficiales (UPME)***


Para consolidar la viabilidad operativa y la validez estructural de la investigación, se realizó un ejercicio de comparación con las proyecciones del modelo ganador (híbrido univariado en escala mensual) frente a los pronósticos oficiales emitidos por la UPME para el mismo horizonte temporal (2026-2029). La Figura 38 ilustra este contraste. El primer hallazgo clave es la congruencia en la estructura: la trayectoria predictiva del modelo propuesto se ajusta de manera íntegra dentro del intervalo de confianza al 95% establecido por la entidad gubernamental. Esto valida que el algoritmo produce estimaciones coherentes y físicamente

posibles con la evolución esperada del mercado eléctrico colombiano, descartando el riesgo de sobreajuste desmedido o una posible extrapolación errática. El MAPE entre la proyección del Escenario Medio de la UPME y las proyecciones del modelo híbrido univariado mensual es de 2.4%, que refleja su elevada similitud.

Sin embargo, se destaca que el modelo híbrido tiende a proyectar una curva situada por encima del valor medio de la UPME, que acentúa con mayor intensidad los picos estacionales de la demanda. Esto sugiere que la arquitectura híbrida tiene una sensibilidad superior a capturar y replicar la varianza de las observaciones históricas frente a los modelos que usan las entidades de planeación del país.

### Figura 38

#### *Comparación con Proyecciones de la UPME*



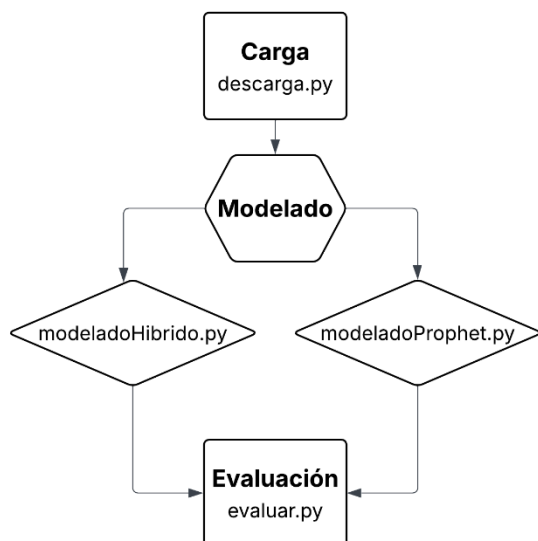
Desde la perspectiva de seguridad del Sistema Nacional, esta sobre estimación puede representar una ventaja estratégica al anticipar escenarios de sobre carga ligeramente más exigente que el promedio oficial. El modelo les brinda a los tomadores de decisiones un margen de planeación operativo más conservador para garantizar la suficiencia de los recursos de generación ante posibles volatilidades del mercado.

## Consolidación del Pipeline

Todo el flujo desde la carga de datos hasta el modelado, evaluación y comparación con proyecciones oficiales fue consignado en cuatro scripts de Python: `descarga.py`; `modeladoHibrido.py`; `modeladoProphet.py` y `evaluar.py` (Figura 39). La ejecución se realiza desde `evaluar.py`, la cual invoca a los módulos de modelado y estas a su vez llaman al módulo de descarga. Con el fin de reducir los tiempos de ejecución, los datos consultados desde XM fueron guardados en CSV tras la primera descarga y los modelos entrenados fueron almacenados en formato JOBLIB (arquitectura híbrida) y JSON (Prophet). El modelado con Prophet siempre fue el más demandante, llegando a necesitar hasta 50 minutos para obtener los mejores hiperparámetros.

**Figura 39**

*Flujo del Pipeline*



## Conclusiones

La presente investigación demuestra el valor estratégico de la analítica de datos para la planeación del sector eléctrico en Colombia. Dada la alta vulnerabilidad de la matriz energética del país ante las anomalías climáticas (como el fenómeno de El Niño), la capacidad de anticipar con precisión la demanda se consolida como una herramienta indispensable para garantizar la confiabilidad del sistema nacional.

El análisis a múltiples resoluciones temporales permitió cuantificar la relación entre la demanda eléctrica y sus variables teóricas de influencia. En la escala temporal a corto plazo (diaria), se demostró que el sistema es autorregresivo; la demanda está explicada en gran medida por su propio comportamiento en los siete días previos ( $r_s = 0.92$ ), y es dominada por el ciclo laboral e industrial de la semana. Por otro lado, al analizar factores macroeconómicos, se comprobó que el crecimiento demográfico es el verdadero motor de la demanda (con una correlación casi perfecta de  $r_s = 0.98$ ). Sin embargo, la restricción de la disponibilidad de esta variable (resolución anual) hace estadísticamente inviable su inclusión directa en modelos de ML por el alto riesgo de sobreajuste. De manera sorprendente, el PIB no exhibió una asociación lineal significativa con la demanda de energía en las escalas trimestrales ni anuales.

Por otro lado, ambos enfoques de modelación (la arquitectura híbrida de Elastic Net con XGB y el modelo de series temporales Prophet) demostraron una robustez excepcional para capturar la demanda diaria y mensual, superando el pronóstico ingenuo estacional ( $MASE < 1$  en la mayoría de los casos). Sin embargo, el hallazgo más valioso de esta fase es la validación de que el enfoque univariado resultó superior y evidencia un mayor desempeño predictivo que el enfoque multivariado. Al prescindir de las variables exógenas como los aportes hidrológicos y el volumen de los embalses, el modelo univariado entregó métricas de error ligeramente mejores y

redujo la incertidumbre operativa. La dependencia de un modelo multivariado exige contar con proyecciones futuras de la precipitación y de los niveles de embalse (los cuales son aleatorios e impredecibles en el largo plazo), haciendo que el modelo univariado sea la solución más estable y autosuficiente para horizontes de extrapolación debido a sus mejores métricas de desempeño predictivo.

Al contrastar las extrapolaciones del modelo campeón (híbrido univariado mensual) frente a las proyecciones de la UPME para el periodo 2026-2029, se comprobó su validez técnica, con un MAPE de 2.4%. La trayectoria del modelo se situó dentro de los intervalos de confianza al 95% de la entidad, sumado al hecho de que esta investigación entre modelos con métricas de desempeño destacables incluso en la resolución diaria, la cual no está presente en las proyecciones de la UPME, que solo cuentan con datos mensuales y anuales.

En adición, la arquitectura basada en ensamble demostró una mayor sensibilidad para capturar los picos estacionales de alta demanda de energía que los modelos tradicionales empleados por la UPME. Esta característica les brinda a los tomadores de decisiones un margen de operación más conservador para garantizar la suficiencia energética del país.

Por último, todo el flujo de trabajo quedó consignado en scripts de Python que facilitan la reproducibilidad de los resultados y funcionan como herramienta de apoyo para investigaciones del sector energético.

## **Recomendaciones**

Este proyecto está centrado en ML y en series de tiempo debido a que es una primera etapa de un proceso de modelado. La principal recomendación es considerar la implementación de redes neuronales ya que en diversos estudios han abordado el problema de dicha manera y los resultados han sido favorables. Asimismo, para ampliar el estudio a futuro, se recomienda la incorporación de otras variables diferente a las mencionadas en el trabajo con el fin de analizar qué otros factores influyen en la demanda de energía eléctrica de Colombia. Esto acompañado de metodologías que permitan aplicar submuestreo de tal manera que las variables trimestrales y anuales, como el PIB y la población, puedan ser llevadas a escala diaria y/o mensual y ser comparadas de manera efectiva con la demanda de energía. Por último, se recomienda implementar modelos multivariados que permitan proyectar la demanda a la par que sus variables exógenas para eliminar la dependencia de introducir manualmente los datos de estas para lograr generar proyecciones en largo plazo.

### Referencias Bibliográficas

- Adha, M. S., Karuru, S. S., Angel, F., & Joling, J. (2026). Bayesian-Optimized Prophet for Tourism-Based Regional Government Revenue Forecasting. *Journal of System and Computer Engineering*, 7(1), 61-62. <https://doi.org/10.61628/jsce.v7i1.2373>
- Aditya Satrio, C. B., Darmawan, W., Nadia, B. U., & Hanafiah, N. (2021). Time series analysis and forecasting of coronavirus disease in Indonesia using ARIMA model and PROPHET. *Procedia Computer Science, 5th International Conference on Computer Science and Computational Intelligence 2020*, 179, 524-532. <https://doi.org/10.1016/j.procs.2021.01.036>
- Ahmed, U., Jiangbin, Z., Almogren, A., Sadiq, M., Rehman, A. U., Sadiq, M. T., & Choi, J. (2024). Hybrid bagging and boosting with SHAP based feature selection for enhanced predictive modeling in intrusion detection systems. *Scientific Reports*, 14(1), 30532. <https://doi.org/10.1038/s41598-024-81151-1>
- Akdi, Y., Gölveren, E., & Okkaoğlu, Y. (2020). Daily electrical energy consumption: Periodicity, harmonic regression method and forecasting. *Energy*, 191, 116524. <https://doi.org/10.1016/j.energy.2019.116524>
- Akter, S., Voumik, L. C., Hossain, Md. S., Esquivias, M. A., & Pattak, D. C. (2025). Examining the impact of environmental and socio-economic factors in countries with high and low child mortality: The role of electricity, healthcare, and industrialization. *Discover Sustainability*, 6(1), 542. <https://doi.org/10.1007/s43621-025-01417-0>
- Alhaj Omar, F., & Pamuk, N. (2026). Comparative Forecasting of Electricity Load and Generation in Türkiye Using Prophet, XGBoost, and Deep Neural Networks. *Sustainability*, 18(6), 2838. <https://doi.org/10.3390/su18062838>

- Alzubi, J., Nayyar, A., & Kumar, A. (2018). Machine Learning from Theory to Algorithms: An Overview. *Journal of Physics: Conference Series*, 1142(1), 012012.  
<https://doi.org/10.1088/1742-6596/1142/1/012012>
- Área Metropolitana del Valle de Aburrá. (s. f.). *Energías Renovables*. Recuperado 2 de noviembre de 2025, de <https://www.metropol.gov.co:443/ambiental/paginas/consumo-sostenible/energias-renovables.aspx>
- Asoenergía. (2020). Resumen Asoenergía sobre Informe XM. *Asoenergía*.  
<https://asoenergia.com/wp-content/uploads/2023/09/Resumen-Demanda-Energia-Asoenergia-Informe-XM-Abril-7-de-2020.pdf>
- Banco de la República. (2024, agosto). *Cambios demográficos recientes y envejecimiento poblacional* | Banco de la República. <https://www.banrep.gov.co/es/blog/cambios-demograficos-recientes-envejecimiento-poblacional>
- Bansal, A., Balaji, K., & Lalani, Z. (2025). *Temporal Encoding Strategies for Energy Time Series Prediction* (arXiv:2503.15456). arXiv. <https://doi.org/10.48550/arXiv.2503.15456>
- Barrientos, J., Marulanda, L. M., & Duque, F. V. (2023). Analyzing Electricity Demand in Colombia: A Functional Time Series Approach. *International Journal of Energy Economics and Policy*, 13(1), 75-84. <https://doi.org/10.32479/ijee.13728>
- Bello, S. A., Hamid, N. S., Abdullah, M., Ameen, M. A., Shehu, J. S., Sharafa, S. B., Aweda, F. O., Yusuf, K. A., & Yahaya, S. (2026). Time Series Forecasting Model of the Ionospheric f<sub>o</sub>F<sub>2</sub> Using Facebook Prophet. *Nigerian Journal of Technological Development*, 23(1), 148-158. <https://doi.org/10.63746/njtd.v23i1.4395>
- Bermúdez, N., & Restrepo, L. (2024). *Nivel de riesgo de mercado en el sector eléctrico colombiano considerando el impacto de los eventos climáticos, la hidrología y la*

*generación térmica en el sistema interconectado nacional.*

<https://hdl.handle.net/10784/34581>

Bi, L., Feleke, A.->Genetu, & Guan, C. (2019). A review on EMG-based motor intention prediction of continuous human upper limb motion for human-robot collaboration.

*Biomedical Signal Processing and Control*, 51, 113-127.

<https://doi.org/10.1016/j.bspc.2019.02.011>

Botchkarev, A. (2019). Performance Metrics (Error Measures) in Machine Learning Regression, Forecasting and Prognostics: Properties and Typology. *Interdisciplinary Journal of*

*Information, Knowledge, and Management*, 14, 045-076. <https://doi.org/10.28945/4184>

Chang, Y.-C., Chang, K.-H., & Wu, G.-J. (2018). Application of eXtreme gradient boosting trees in the construction of credit risk assessment models for financial institutions. *Applied Soft*

*Computing*, 73, 914-920. <https://doi.org/10.1016/j.asoc.2018.09.029>

Chukwura, J., & Chinenye, I. (2023). *A Review of Techniques for Regularization*. ResearchGate.

[https://www.researchgate.net/publication/367546346\\_A\\_Review\\_of\\_Techniques\\_for\\_Regularization](https://www.researchgate.net/publication/367546346_A_Review_of_Techniques_for_Regularization)

Colmenares, J. S., & Pardo, C. P. (2021). Colombia 1959-2014: Transformación demográfica e implicaciones socioeconómicas. *Revista Grafía*, 18(2), 23 págs-23 págs.

Contreras, D. (2016). El impacto de El Niño en Colombia. *Revista Fasecolda*, (163), 42-46.

Cordeschi, R. (2007). Ai Turns Fifty: Revisiting Its Origins. *Applied Artificial Intelligence*, 21(4-5), 259-279. <https://doi.org/10.1080/08839510701252304>

da Silva, E. G., de Mattos Neto, P. S. G., & de Oliveira, J. F. L. (2019). Hybrid System for Time Series using Iterative Residual Forecasting Models. *2019 8th Brazilian Conference on*

*Intelligent Systems (BRACIS)*, 872-877. <https://doi.org/10.1109/BRACIS.2019.00155>

- Dagum, E. B. (2010). Time series modeling and decomposition. *Statistica*, 70(4), 433-457.  
<https://doi.org/10.6092/issn.1973-2201/3597>
- Deepika, & Pandove, G. (2025). Prediction of traffic time using XGBoost model with hyperparameter optimization. *Multimedia Tools and Applications*, 84(30), 37045-37090.  
<https://doi.org/10.1007/s11042-025-20646-z>
- Departamento Administrativo Nacional de Estadística. (s. f.). *PROYECCIONES DE POBLACIÓN* [Dataset]. Recuperado <https://www.dane.gov.co/index.php/estadisticas-por-tema/demografia-y-poblacion/proyecciones-de-poblacion>
- Departamento Administrativo Nacional de Estadística. (2016). *¿Conoce qué son las series de tiempo y las series desestacionalizadas?* <https://www.dane.gov.co/index.php/actualidad-dane/3886-que-tipo-de-datos-usa-en-su-vida-cotidiana-3>
- Departamento Administrativo Nacional de Estadística. (2021). *Proyecciones de población*.  
<https://www.dane.gov.co/index.php/estadisticas-por-tema/demografia-y-poblacion/proyecciones-de-poblacion>
- Departamento Administrativo Nacional de Estadística. (2023). *Proyecciones de población—Indicadores demográficos*. <https://www.dane.gov.co/files/censo2018/proyecciones-de-poblacion/presentacion-Proypoblacion-IndDemograficos-ActPostCOVID.pdf>
- Departamento Administrativo Nacional de Estadística. (2026a). *DANE - Históricos Producto Interno Bruto -PIB-*. <https://www.dane.gov.co/index.php/estadisticas-por-tema/cuentas-nacionales/cuentas-nacionales-trimestrales/historicos-producto-interno-bruto-pib>
- Departamento Administrativo Nacional de Estadística. (2026b). *Producto Interno Bruto (PIB) nacional trimestral* [Dataset]. <https://www.dane.gov.co/index.php/estadisticas-por-tema/cuentas-nacionales/cuentas-nacionales-trimestrales/pib-informacion-tecnica>

- Department of Economic and Social Affairs. (2024). *World Population Prospects 2024—Summary of results* (p. 80). United Nations.  
[https://www.un.org/development/desa/pd/sites/www.un.org.development.desa.pd/files/files/documents/2024/Jul/wpp2024\\_summary\\_of\\_results\\_final\\_web.pdf](https://www.un.org/development/desa/pd/sites/www.un.org.development.desa.pd/files/files/documents/2024/Jul/wpp2024_summary_of_results_final_web.pdf)
- Desai, S., Dalal, T., Kadam, S., & Mishra, S. (2021). Electrical Load Forecasting using Machine Learning. *2021 International Conference on System, Computation, Automation and Networking (ICSCAN)*, 1-6. <https://doi.org/10.1109/ICSCAN53069.2021.9526444>
- ENEL. (2025). *Energías renovables y no renovables ¿qué son? | Enel*.  
<https://enel.com.co/content/enel-co/es/megamenu/historias/archive/2020/11/diferencia-energia-renovable-no-renovable.html>
- Filik, Ü. B., Gerek, Ö. N., & Kurban, M. (2011). A novel modeling approach for hourly forecasting of long-term electric energy demand. *Energy Conversion and Management*, 52(1), 199-211. <https://doi.org/10.1016/j.enconman.2010.06.059>
- Gándara, Ó. (2024). *Electricidad y Magnetismo, desde Oersted hasta la Relatividad Especial de Einstein*. <https://uvadoc.uva.es/handle/10324/69146>
- Hernández, C. A. O. (2024). Origen e importancia de la electricidad. *Vida Científica Boletín Científico de la Escuela Preparatoria No. 4*, 12(23), 15-18.  
<https://doi.org/10.29057/prepa4.v12i23.11922>
- Higginbotham, J., & Walker, J. (2026). *Harmonic Forecasting of Annual Peak Snow Water Equivalent at SNOTEL Monitoring Stations Across the Western United States* (No. 2026040438). Preprints. <https://doi.org/10.20944/preprints202604.0438.v1>
- Hinman, J., & Hickey, E. (2009). Modeling and forecasting short-term electricity load using regression analysis. *Journal of Institute for Regulatory Policy Studies*, 1-51.

- Huang, H., Xu, Z., Li, X., Liu, B., Fan, X., Ding, H., Xu, W., Huang, H., Xu, Z., Li, X., Liu, B., Fan, X., Ding, H., & Xu, W. (2025). Predicting Rheological Properties of Asphalt Modified with Mineral Powder: Bagging, Boosting, and Stacking vs. Single Machine Learning Models. *Materials*, *18*(12). <https://doi.org/10.3390/ma18122913>
- Hussain, I., Ching, K. B., Utraphan, C., Tay, K. G., Memon, I., & Memon, S. A. (2025). Predicting Monthly Wind Speeds Using XGBoost: A Case Study for Renewable Energy Optimization. *Processes*, *13*(6), 1763. <https://doi.org/10.3390/pr13061763>
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice*. <https://research.monash.edu/en/publications/forecasting-principles-and-practice-2/>
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, *22*(4), 679-688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
- Jamil, B., & Akhtar, N. (2017). Comparative analysis of diffuse solar radiation models based on sky-clearness index and sunshine period for humid-subtropical climatic region of India: A case study. *Renewable and Sustainable Energy Reviews*, *78*, 329-355. <https://doi.org/10.1016/j.rser.2017.04.073>
- Jiang, T., Gradus, J. L., & Rosellini, A. J. (2020). Supervised Machine Learning: A Brief Primer. *Behavior Therapy*, *51*(5), 675-687. <https://doi.org/10.1016/j.beth.2020.05.002>
- Jiménez, J. A. (2025). *Estrategia didáctica para facilitar la enseñanza del concepto de generación eléctrica usando componentes de bajo costo*. <https://repositorio.unal.edu.co/handle/unal/88316>

- Jin, X., Zhang, S., Zhao, Q., Jiang, Z., Zhao, G., & Fang, J. (2025). Solar Power Generation Forecasting Based on Improved Elastic Net Regression. *International Journal of High Speed Electronics and Systems*, 2540738. <https://doi.org/10.1142/S0129156425407387>
- Lee, M., Ser, Y. C., Selvachandran, G., Thong, P. H., Cuong, L., Le Hoang Son, Nguyen Trung Tuan, & Vassilis C. Gerogiannis. (2022). A Comparative Study of Forecasting Electricity Consumption Using Machine Learning Models. *Mathematics*, 10(8), 1329. <https://doi.org/10.3390/math10081329>
- Ley de energía Eléctrica, Legislation No. 143 (1994). Por la cual se establece el régimen para la generación, interconexión, transmisión, distribución y comercialización de electricidad en el territorio nacional, se conceden unas autorizaciones y se dictan otras disposiciones en materia energética.
- Li, B., & Gilbert, S. (2024). Artificial Intelligence awarded two Nobel Prizes for innovations that will shape the future of medicine. *Npj Digital Medicine*, 7(1), 336. <https://doi.org/10.1038/s41746-024-01345-9>
- Li, Y. (2019). *Reinforcement Learning Applications* (arXiv:1908.06973). arXiv. <https://doi.org/10.48550/arXiv.1908.06973>
- Libriawan, R. D., Sari, A. P., & Wahanani, H. E. (2025). Implementation of Facebook Prophet Algorithm in Population Prediction. *Bit-Tech*, 8(2), 2016-2026. <https://doi.org/10.32877/bt.v8i2.3190>
- Maisueche, A. (2019). *Utilización del Machine Learning en la industria 4.0*. <https://uvadoc.uva.es/handle/10324/37908>
- Manrique, E. (2020). *Machine Learning: Análisis de lenguajes de programación y herramientas para desarrollo*.

<https://www.proquest.com/openview/c7e24c997199215aa26a39107dd2fe98/1?pq-origsite=gscholar&cbl=1006393>

Marín, J. S. G., Carvajal, S. X., & Manrique, A. A. (2015). Programas de gestión de demanda de electricidad para el sector residencial en Colombia: Enfoque Sistémico. *Energética*, (46), 73-83.

Maryasin, O. Yu., & Lukashov, A. I. (2020). A Python Application for Hourly Electricity Prices Forecasting Using Neural Networks. *2020 International Russian Automation Conference (RusAutoCon)*, 138-143. <https://doi.org/10.1109/RusAutoCon49822.2020.9208035>

Mathworks. (s. f.). *Análisis de series temporales: Pasos, tipos y ejemplos*. Recuperado 20 de abril de 2026, de <https://la.mathworks.com/discovery/time-series-analysis.html>

Mehdary, A., Chehri, A., Jakimi, A., & Saadane, R. (2024). Hyperparameter Optimization with Genetic Algorithms and XGBoost: A Step Forward in Smart Grid Fraud Detection. *Sensors*, 24(4), 1230. <https://doi.org/10.3390/s24041230>

Meta Open Source. (s. f.). *Trend Changepoints*. Prophet. Recuperado 15 de mayo de 2026, de [http://facebook.github.io/prophet/docs/trend\\_changepoints.html](http://facebook.github.io/prophet/docs/trend_changepoints.html)

Miller, D. L. (2025). Bayesian views of generalized additive modelling. *Methods in Ecology and Evolution*, 16(3), 446-455. <https://doi.org/10.1111/2041-210X.14498>

Monteiro, F. P., Monteiro, S., Rodrigues, C., Reis, J., Bezerra, U., Tostes, M. E., & Almeida, F. A. F. (2025). A Hybrid Methodology Using Machine Learning Techniques and Feature Engineering Applied to Time Series for Medium- and Long-Term Energy Market Price Forecasting. *Energies*, 18(6), 1387. <https://doi.org/10.3390/en18061387>

Moskalev, A. (2019). *Demand forecasting for fast-moving products in grocery retail*. <https://aaltodoc.aalto.fi/handle/123456789/37915>

- Muñoz Romero, M. (2024). *Análisis de la implementación del proceso de conexiones al sistema interconectado nacional y su efecto en la diversificación de la matriz energética colombiana*. <https://bdigital.uexternado.edu.co/handle/001/28001>
- Myttenaere, A., Golden, B., Le Grand, B., & Rossi, F. (2016). Mean Absolute Percentage Error for regression models. *Neurocomputing, Advances in artificial neural networks, machine learning and computational intelligence*, 192, 38-48.  
<https://doi.org/10.1016/j.neucom.2015.12.114>
- Nguinabé, J., Rockefeller, R., Khan, N. M., & Rodrigues, P. C. (2025). Bootstrap prediction intervals for the long short term memory (LSTM) recurrent neural network. *Expert Systems with Applications*, 284, 127728. <https://doi.org/10.1016/j.eswa.2025.127728>
- Ogut, J. O., Schulz-Streeck, T., & Piepho, H.-P. (2012). Genomic selection using regularized linear regression models: Ridge regression, lasso, elastic net and their extensions. *BMC Proceedings*, 6(2), S10. <https://doi.org/10.1186/1753-6561-6-S2-S10>
- Oluwasakin, E., Torku, T., Tingting, S., Yinusa, A., Hamdan, S., Poudel, S., Hasan, N., Vargas, J., & Poudel, K. (2023). Minimization of high computational cost in data preprocessing and modeling using MPI4Py. *Machine Learning with Applications*, 13, 100483.  
<https://doi.org/10.1016/j.mlwa.2023.100483>
- Osorio, W. J. (2025). *Uso del Machine Learning en la predicción de la demanda de energía en Colombia*. <http://repository.unad.edu.co/handle/10596/70599>
- Pereira, R. (2016). *Definiciones Fundamentales*.  
<https://repositoriotec.tec.ac.cr/handle/2238/10130>

- Pérez, G. J. (2006). Dinámica demográfica y desarrollo regional en Colombia. *Documentos de Trabajo Sobre Economía Regional y Urbana, Documentos de Trabajo Sobre Economía Regional y Urbana*, Article 2359. <https://doi.org/10.32468/dtseru.78>
- Pinzón, J. D., Osorno, T., Mola, J. A., & Valencia, A. (2020). Real-time Health Condition Monitoring of SCADA Infrastructure of Power Transmission Systems Control Centers. *2020 IEEE PES Transmission & Distribution Conference and Exhibition - Latin America (T&D LA)*, 1-6. <https://doi.org/10.1109/TDLA47668.2020.9326135>
- RAE. (s. f.). *Electricidad* | *Diccionario de la lengua española*. «Diccionario de la lengua española» - Edición del Tricentenario. Recuperado 2 de noviembre de 2025, de <https://dle.rae.es/electricidad>
- Rayer, S., Smith, S. K., & Tayman, J. (2009). Empirical Prediction Intervals for County Population Forecasts. *Population Research and Policy Review*, 28(6), 773-793. <https://doi.org/10.1007/s11113-009-9128-7>
- Reddy, G. V., Aitha, L. J., Poojitha, C., Shreya, A. N., Reddy, D. K., & Meghana, G. S. (2023). Electricity Consumption Prediction Using Machine Learning. *E3S Web of Conferences*, 391, 01048. <https://doi.org/10.1051/e3sconf/202339101048>
- República de Colombia, Legislation No. 680 (1992). Decreto 680 de 1992: Por el cual se declara el Estado de Emergencia Económica y Social. Diario Oficial No. 40.423.
- República de Colombia, Legislation No. 385 (2020). Por la cual se declara la emergencia sanitaria por causa del coronavirus COVID-19 y se adoptan medidas para hacer frente al virus

- Rodriguez, J. (2025). *Supervised Machine Learning Models Evaluation to Forecast Preventive Maintenance Costs in a Thermal Power Plant* [Ph.D. thesis].  
<https://ui.adsabs.harvard.edu/abs/2025PhDT.....3R>
- Rosenblatt, M., Tejavibulya, L., Jiang, R., Noble, S., & Scheinost, D. (2024). Data leakage inflates prediction performance in connectome-based machine learning models. *Nature Communications*, 15(1), 1829. <https://doi.org/10.1038/s41467-024-46150-w>
- Rudnick, H., & Velásquez, C. (2021). *Learning from Power Sector Reform Experiences: The Case of Colombia* [Text/HTML]. The World Bank.  
<https://documentos.bancomundial.org/es/publication/documents-reports/documentdetail/099935002022214889>
- Schober, P., Boer, C., & Schwarte, L. A. (2018). Correlation Coefficients: Appropriate Use and Interpretation. *Anesthesia & Analgesia*, 126(5), 1763.  
<https://doi.org/10.1213/ANE.0000000000002864>
- Schröer, C., Kruse, F., & Gómez, J. M. (2021). A Systematic Literature Review on Applying CRISP-DM Process Model. *Procedia Computer Science, CENTERIS 2020 - International Conference on ENTERprise Information Systems / ProjMAN 2020 - International Conference on Project MANagement / HCist 2020 - International Conference on Health and Social Care Information Systems and Technologies 2020, CENTERIS/ProjMAN/HCist 2020*, 181, 526-534.  
<https://doi.org/10.1016/j.procs.2021.01.199>
- Shivashankar, K., Hajj, G. S. A., & Martini, A. (2025). *Scalability and Maintainability Challenges and Solutions in Machine Learning: Systematic Literature Review* (arXiv:2504.11079). arXiv. <https://doi.org/10.48550/arXiv.2504.11079>

- Silva, M. G., Madeira, S. C., & Henriques, R. (2026). Cutting through the noise: Explaining residuals in multivariate time series with motif analysis. *Pattern Recognition*, *169*, 111900. <https://doi.org/10.1016/j.patcog.2025.111900>
- Sleem, A. A., & Syed, M. N. (2025). Novel Predictive Factors to Boost Short-Term Electricity Demand Forecasting Using Machine Learning Models. *IEEE Access*, *13*, 147265-147290. <https://doi.org/10.1109/ACCESS.2025.3600864>
- Stern, D. I., Burke, P. J., & Bruns, S. B. (2019). *The Impact of Electricity on Economic Development: A Macroeconomic Perspective*. <https://escholarship.org/uc/item/7jb0015q>
- Stryker, C., & Kavlakoglu, E. (s. f.). *¿Qué es la Inteligencia Artificial (IA)? | IBM*. Recuperado 3 de noviembre de 2025, de <https://www.ibm.com/es-es/think/topics/artificial-intelligence>
- Tabares, J. F., & Velásquez, C. A. (2013). *Optimización del abastecimiento energético de Colombia, usando una técnica de pronóstico eficiente para la demanda*. <http://hdl.handle.net/20.500.11912/1135>
- Taylor, S. J., & Letham, B. (2017). *Forecasting at scale* (E3190v2). PeerJ Inc. <https://doi.org/10.7287/peerj.preprints.3190v2>
- The Pennsylvania State University. (2024). *Seasonal Models – STAT 510 | Applied Time Series Analysis*. <https://online.stat.psu.edu/stat510/Lesson04>
- Toledo-Cortés, S., Lara, J. S., Zambrano, A., González, F. A., & Garcia, J. R. (2023). Characterization of electricity demand based on energy consumption data from Colombia. *International Journal of Electrical and Computer Engineering (IJECE)*, *13*(5), 4798-4809. <https://doi.org/10.11591/ijece.v13i5.pp4798-4809>
- Turing, A. M. (1950). Computing machinery and intelligence. *Mind*, *59*, 433-460. <https://doi.org/10.1093/mind/LIX.236.433>

- Unidad de Planeación Minero Energética. (2025a). *Proyección de demanda de energía eléctrica y potencia máxima a escala Nacional y por áreas eléctricas con resolución anual y mensual*. Unidad de Planeación Minero Energética.  
[https://docs.upme.gov.co/DemandayEficiencia/Documents/Proyecciones\\_de\\_demanda\\_2025-2039\\_v4.pdf](https://docs.upme.gov.co/DemandayEficiencia/Documents/Proyecciones_de_demanda_2025-2039_v4.pdf)
- Unidad de Planeación Minero Energética. (2025b). *Proyección de la demanda de energía eléctrica y potencia máxima 2025-2039*. Unidad de Planeación Minero Energética.  
[https://docs.upme.gov.co/DemandayEficiencia/Documents/Proyecciones\\_de\\_demanda\\_2025-2039\\_v4.pdf](https://docs.upme.gov.co/DemandayEficiencia/Documents/Proyecciones_de_demanda_2025-2039_v4.pdf)
- Unidad de Planeación Minero Energética. (2025c). *Proyecciones de demanda* [Dataset].  
[https://www.upme.gov.co/simec/planeacion-energetica/proyeccion\\_de\\_demanda/](https://www.upme.gov.co/simec/planeacion-energetica/proyeccion_de_demanda/)
- Universidad de Indiana. (s. f.). *The Nyquist Limit*. Electron Microscopy Center. Recuperado 15 de mayo de 2026, de <http://iubemcenter.indiana.edu/equipment/tips-and-help/nyquist-limit/index.html>
- Universidad Europea. (2025). *¿Qué son las energías no renovables?* | *Blog UE*. Universidad Europea. <https://universidadeuropea.com/blog/energias-no-renovables/>
- Universidad ORT. (s. f.). *Qué es la electricidad y quién la descubrió—Universidad ORT Uruguay*. Recuperado 2 de noviembre de 2025, de <https://fi.ort.edu.uy/blog/que-es-la-electricidad-y-quien-la-descubrio>
- Valero Fandiño, J. C. (2013). *Análisis de series de tiempo de caudal mediante la transformada de Fourier*. <http://hdl.handle.net/20.500.11912/5075>

- Velásquez, J. D., Franco, C. J., & García, H. A. (2009). Un modelo no lineal para la predicción de la demanda mensual de electricidad en Colombia. *Estudios Gerenciales*, 25(112), 37-54. [https://doi.org/10.1016/S0123-5923\(09\)70079-8](https://doi.org/10.1016/S0123-5923(09)70079-8)
- Welagedara, W. A. D. M., Haile, M. G., & Olive, D. J. (2026). ARIMA Model Selection and Prediction Intervals. *Axioms*, 15(3), 228. <https://doi.org/10.3390/axioms15030228>
- World Health Organization, The World Bank, International Renewable Energy Agency, & Sustainable Energy for All. (2023). *Energizing health: Accelerating electricity access in health-care facilities: executive summary*. <https://www.who.int/publications/i/item/9789240066984>
- XM SA ESP. (s. f.-a). *Históricos de Demanda de Energía en Colombia – XM*. Recuperado 14 de marzo de 2026, de <https://www.xm.com.co/consumo/historicos-de-demanda>
- XM SA ESP. (s. f.-b). *Pydataxm* (Versión 0.3.17) [Software]. GitHub. [https://github.com/EquipoAnaliticaXM/API\\_XM](https://github.com/EquipoAnaliticaXM/API_XM)
- Zhao, X., Ma, Z. G., & Jørgensen, B. N. (2025). An End-to-End Data and Machine Learning Pipeline for Energy Forecasting: A Systematic Approach Integrating MLOps and Domain Expertise. *Information*, 16(9), 805. <https://doi.org/10.3390/info16090805>
- Zheng, Y., & Stodden, V. (2024). The Idealized Machine Learning Pipeline (IMLP) for Advancing Reproducibility in Machine Learning. *Proceedings of the 2nd ACM Conference on Reproducibility and Replicability, ACM REP '24*, 110-120. <https://doi.org/10.1145/3641525.3663630>
- Zherlitsyn, D., Kharchenko, V., & Kharchenko, H. (2025). Enhancing wheat price forecasting accuracy through Prophet based models: 2025 International Workshop on Computational

Intelligence. *Proceedings of the International Workshop on Computational Intelligence (IWSCI 2025), CEUR Workshop Proceedings, 4035*, 105-116.

Zhou, L., Zhao, P., Wu, D., Cheng, C., & Huang, H. (2018). Time series model for forecasting the number of new admission inpatients. *BMC Medical Informatics and Decision Making, 18*(1), 39. <https://doi.org/10.1186/s12911-018-0616-8>

## Apéndices

### Apéndice A

#### *Software Utilizado y Recursos Técnicos*

Para la implementación de los modelos, se utilizó el software Python, versión 3.12.10, ejecutado desde el entorno de desarrollo Visual Studio Code. Durante el desarrollo de los análisis se implementaron diversas librerías, entre ellas: Numpy y Pandas, utilizadas para la carga y transformación de los datos; Matplotlib y Seaborn, usadas en la visualización de todas las figuras; Scikit-Learn y XGBoost, usadas en la modelación de la arquitectura híbrida y Prophet, usado en la arquitectura de series de tiempo.

El procesamiento de todos los análisis y modelado de datos fue realizado en un equipo con ocho núcleos de procesamiento y 16 GB de memoria RAM. El tiempo de ejecución promedio de cada bloque de código fue aproximadamente 5 segundos, con excepción de la validación de hiperparámetros, la cual requirió en promedio 30 minutos por modelo debido a la intensidad computacional y el número de iteraciones requeridas.