

Uso del Machine Learning en la predicción de la demanda de energía en Colombia

Wilson Javier Osorio Guevara

Asesor

Isaac Esteban Camargo Freile

Universidad Nacional Abierta y a Distancia UNAD

Escuela de Ciencias Básica Tecnología e Ingeniería ECBTI

Especialización en Ciencia de Datos y Analítica

2025

Dedicatoria

A la vida, por darme la oportunidad de escalar un paso más en mi formación profesional; por enseñarme que cada meta alcanzada es fruto de la constancia, el esfuerzo y la fe en uno mismo.

Por mostrarme y enseñarme el valor de la perseverancia en cada paso dado, por brindarme la fuerza cuando sentí que flaqueaba y la lucidez mental para mantenerme firme frente a los retos y desafíos que surgieron en este hermoso proceso de aprendizaje.

A la vida, por recordarme que los sueños no se alcanzan de un salto, sino caminando con perseverancia, fe, valentía, convicción, esfuerzo y pasión.

Agradecimientos

A la Universidad Nacional Abierta y a Distancia – UNAD, por brindarme la oportunidad de prepararme académica y profesionalmente. Gracias por abrirme las puertas al conocimiento, por ofrecer un espacio de formación flexible e inclusivo, y por ser el escenario donde pude construir este sueño paso a paso.

Quiero expresar mi más sincero agradecimiento a los docentes que me acompañaron a lo largo de este proceso, por su dedicación, paciencia, sabiduría, mentoría y profesionalismo. Mil gracias por compartir sus conocimientos y por estar siempre dispuestos a guiarme en cada fase de este trabajo. Sus enseñanzas y acompañamiento han sido fundamentales para alcanzar esta anhelada meta; su apoyo constante me impulsó a seguir aprendiendo y creciendo en cada etapa de este proyecto.

A todas las personas que, de una u otra manera, contribuyeron a hacer posible este proyecto, gracias por su tiempo, paciencia y colaboración. Cada aporte fue valioso y dejó una huella significativa en este camino.

Resumen

Este estudio analiza la aplicación de técnicas de Machine Learning (ML) en la predicción de la demanda energética en Colombia. El objetivo principal es evaluar la viabilidad de utilizar modelos de ML para optimizar la gestión energética en el país, considerando experiencias internacionales exitosas. La metodología empleada es cualitativa, basada en una revisión sistemática de literatura que incluye casos de éxito en países como Turquía, India Arabia Saudita e Indonesia. Los principales hallazgos destacan la efectividad y aplicabilidad de los enfoques híbridos y de ensamble, como las redes neuronales y las máquinas de soporte vectorial, en la mejora de la precisión predictiva. Se concluye que, aunque el uso de ML es prometedor, su implementación en Colombia enfrenta retos relacionados con la infraestructura de datos y la formación técnica. Se recomienda avanzar con estudios piloto y fortalecer la cooperación internacional para adaptar los modelos al contexto colombiano.

Palabras claves: Software, predicción, Machine Learning, datos, energía.

Abstract

This study analyzes the application of Machine Learning (ML) techniques in energy demand forecasting in Colombia. The main objective is to evaluate the feasibility of using ML models to optimize energy management in the country, considering successful international experiences. The methodology employed is qualitative, based on a systematic literature review that includes case studies from countries like Turkey, India, Saudi Arabia, and Indonesia. Key findings highlight the effectiveness of hybrid and ensemble approaches, such as neural networks and support vector machines, in improving prediction accuracy. It is concluded that while the use of ML is promising, its implementation in Colombia faces challenges related to data infrastructure and technical training. It is recommended to proceed with pilot studies and strengthen international cooperation to adapt models to the Colombian context.

Keywords: Software, prediction, Machine Learning, data, energy.

Tabla de Contenido

Introducción	9
Planteamiento del Problema.....	12
Justificación	14
Objetivos.....	18
Objetivo General	18
Objetivos Específicos	18
Marco Conceptual.....	19
Inteligencia Artificial	19
Machine Learning (Aprendizaje Automático).	20
Marco teórico.	23
Inteligencia Artificial en el Sector Energético.	23
Aprendizaje Automático en la Predicción de la Demanda Energética.....	23
Metodología	27
Casos de Éxito y Hallazgos Clave en la Aplicación de Machine Learning para la Predicción de la Demanda.....	31
Factores que Influyen en la Precisión de las Predicciones de la Demanda	36
Discusión.....	40
Conclusiones	44
Referencias Bibliográficas	46

Lista de Tablas

Tabla 1 <i>Modelos de Machine Learning Utilizados</i>	34
--	----

Lista de Figuras

Figura 1 <i>Tipos de Aprendizaje y Modelos de Machine Learning</i>	21
Figura 2 <i>Diagrama del Proceso Inclusión/Exclusión de la Bibliografía.</i>	27
Figura 3 <i>Diagrama Global de Revisión de la Bibliografía</i>	30

Introducción

En las últimas décadas, el crecimiento sostenido de la demanda energética ha sido una tendencia global, impulsada por el desarrollo económico, el aumento poblacional y la acelerada electrificación de sectores como la industria, el transporte y los servicios, según el informe anual de análisis y proyecciones globales de la Agencia Internacional de la Energía (AIE, 2024). A nivel internacional, la demanda global de energía creció un 2,2% en 2024, mientras que la demanda de energía eléctrica aumentó un 4,3%, superando el ritmo de crecimiento económico mundial. Este fenómeno se ha visto especialmente acentuado en economías emergentes y en desarrollo, que concentraron más del 80% del incremento en la demanda energética, destacando el papel de países como China e India (Kerui Du, Shao & Yan, 2021). Además, el crecimiento de la generación eléctrica ha estado liderado por fuentes renovables y nucleares, que en conjunto representaron el 40% de la generación total, con las renovables aportando el 32% del suministro mundial en 2024 (AIE, 2024).

En el contexto latinoamericano, la matriz energética está dominada por hidrocarburos, donde el gas natural y el petróleo representan cerca del 65% del consumo total, según informe de la Comisión Económica para América Latina y el Caribe (CEPAL, 2023). Sin embargo, la región se distingue por una alta participación de energías renovables en la generación eléctrica, alcanzando el 75%, principalmente gracias a la hidroelectricidad, que aporta alrededor del 80% de la electricidad renovable (CEPAL, 2023). El sector transporte es el principal consumidor de energía, seguido por la industria y el sector residencial (Miranda, 2019). Las proyecciones regionales indican que el consumo de energía primaria continuará incrementándose a un ritmo promedio de 1,12% anual hasta 2040, manteniéndose la preponderancia de energías fósiles y la

hidroenergía, aunque se prevé un avance gradual en la diversificación hacia otras fuentes renovables (CEPAL, 2023).

En los últimos años, la demanda de energía ha venido creciendo de manera sostenida en Colombia, impulsada por varios factores como el aumento de la población, la expansión del sector empresarial y el desarrollo de proyectos de infraestructura a nivel local, regional y nacional (Xpertia en Mercado de Energía - XM, 2025; Banco Bilbao Vizcaya Argentaria - BBVA Research, 2021). Este crecimiento presenta grandes desafíos para el sector, especialmente en términos de la capacidad de predecir y gestionar la demanda de energía de forma precisa y eficiente según informe de la Unidad de Planeación Minero-Energética (UPME), (UPME, citado en Climate Tracker Latam, 2024; Cortázar & Villanueva, 2025). Por ejemplo, en 2022, la demanda de energía en Colombia fue de 76.655 GWh, lo que representó un crecimiento de 3,31% con respecto al año anterior (Informe Perspectiva Sectorial - Energía, 2023). Además, la planificación y el ajuste de las proyecciones de demanda energética son cruciales para garantizar la exactitud necesaria para tomar decisiones estratégicas. Según proyecciones, se espera que la demanda de energía eléctrica continúe creciendo en los próximos años, con estimaciones que indican un consumo diario entre 191 a 232 GWh-día en los años próximos, según informe de la Unidad de Planeación Minero-Energética (UPME, s.f.). En este contexto, el uso de herramientas avanzadas como el Machine Learning (ML) se ha perfilado como una posible solución para mejorar la predicción de la demanda energética. A nivel global, diversas investigaciones han evidenciado la efectividad de modelos de aprendizaje automático para abordar problemas complejos en el sector energético, tales como la predicción de fallos en la red y la estimación de precios (Galvis Plata, 2022).

Sin embargo, en Colombia, la literatura sobre el uso de estas tecnologías es aún limitada, y el sector sigue confiando en métodos tradicionales que no siempre cumplen con las exigencias de precisión requeridas para una correcta toma de decisiones. La implementación de modelos predictivos basados en Machine Learning podría representar un avance significativo en la gestión eficiente del consumo energético y en la planificación estratégica del sector.

Planteamiento del Problema

A nivel global, la predicción de la demanda energética es un ejercicio crucial para garantizar la eficiencia y la sostenibilidad del suministro de energía. Este proceso implica analizar variables históricas, económicas, demográficas y climáticas para estimar el comportamiento futuro de la demanda. La Agencia Internacional de la Energía (AIE) destaca la importancia de las energías renovables en el futuro del consumo energético global, con un crecimiento significativo en la adopción de fuentes como la solar y la eólica (Cuerva Energía, 2024).

En el contexto colombiano, la proyección de la demanda energética es igualmente vital. Generalmente se requiere un análisis anual que combina datos de fuentes estatales como la Unidad de Planeación Minero Energética (UPME), la Empresa Colombiana de Petróleos (ECOPETROL), el Ministerio de Minas y Energía (MEM), la Administración Nacional Oceánica y Atmosférica de Estados Unidos (NOAA), Interconexión Eléctrica S.A. (ISA), Empresas Públicas de Medellín (EPM), el Banco de la República y el Departamento Administrativo Nacional de Estadística (DANE), entre otras (UPME, 2010; Medina & García, 2005; Departamento Nacional de Planeación (DNP, 2017). Sin embargo, los métodos tradicionales de predicción presentan limitaciones en términos de certidumbre y eficiencia, como lo demuestran estudios recientes en el contexto colombiano. Por ejemplo, Tabares y Velásquez (2021) evidenciaron que modelos clásicos como SARIMA y la suavización exponencial tienen dificultades para capturar comportamientos atípicos en la demanda energética diaria del país, especialmente durante periodos estacionales críticos, lo que genera errores significativos en la planificación del abastecimiento. Esta situación se agrava por la dependencia excesiva de patrones históricos, que no incorporan variables exógenas clave como cambios climáticos o

crisis económicas, como señala el estudio del Banco Interamericano de Desarrollo (BID) y la UPME (2024). Según Grimaldo (2013) y Grimaldo, Mendoza y Reyes (2016), es necesario mejorar la precisión y reducir los tiempos de procesamiento en la predicción de la demanda energética.

La aplicación de técnicas de Machine Learning (ML) en la predicción de la demanda energética ha demostrado ser prometedora a nivel global, permitiendo mejoras en la precisión y reducción de los tiempos de procesamiento (Torres Sánchez, 2023). La viabilidad del uso de Machine Learning en la predicción de la demanda energética en Colombia puede ser alta, ya que puede facilitar un mayor nivel de certidumbre y eficiencia en comparación con los métodos tradicionales, según el informe de la empresa tecnológica Dexma Energy Intelligence (Dexma, 2024).

Por lo cual, el presente trabajo plantea la siguiente pregunta de investigación: ¿Cuál es la viabilidad del uso de técnicas de Machine Learning en la predicción de la demanda energética en Colombia?

Justificación

A nivel global, la demanda de energía está experimentando un crecimiento significativo, impulsado por factores como el aumento de la población y la industrialización. Según la Agencia Internacional de la Energía (AIE), la demanda mundial de electricidad crecerá a un promedio de un 3,4% entre 2024 y 2026, con un fuerte impulso de las energías renovables y la nuclear para cubrir este aumento. A largo plazo, la demanda eléctrica mundial se duplicará para 2050, impulsada por la electrificación del transporte y la industria de acuerdo con la Organización Internacional de Aseguramiento y Gestión de Riesgos, (DNV, 2024).

En América Latina, la demanda energética muestra un crecimiento moderado en comparación con regiones como Asia, aunque enfrenta desafíos estructurales en su transición hacia energías renovables, donde la generación eléctrica con fuentes limpias pasó del 53% al 65% entre 2015 y 2022, liderada por hidroelectricidad, de acuerdo con la Organización Latinoamericana de Energía, (OLADE, 2023), aunque el IEA (2023) proyecta que la demanda de electricidad crecerá entre un 90% y 180% para 2050, presionando la escalada de infraestructura limpia. Países como Brasil mantienen una matriz eléctrica con más del 80% de renovables, destacando hidroeléctricas y expansión agresiva de eólica y solar (IEA, 2023), mientras Chile logró que solar y eólica representen el 30% de su generación en 2023, con planes para alcanzar el 70% para 2030, según la Comisión Económica para América Latina y el Caribe, (CEPAL, 2023; IEA, 2023). Sin embargo, persisten retos como la dependencia del 65% en gas natural y petróleo (OLADE, 2023), la necesidad de triplicar inversiones en renovables para cumplir metas climáticas (IEA, 2023), y la desigualdad en acceso que afecta a 14 millones de personas (CEPAL, s.f.), pese a avances como el crecimiento anual del 69% en solar y 36% en eólica

durante la última década (BID, 2023), y políticas innovadoras como las subastas chilenas que redujeron precios solares a \$20/MWh, replicadas en Colombia y Perú (IEA, 2023).

En Colombia, al igual que en los países ya mencionados, la demanda de energía tiende al crecimiento cada año debido a factores como el crecimiento de la población, el aumento de la inversión extranjera, proyectos de infraestructura, y aspectos climatológicos (Grimaldo, 2013; Medina & García, 2005; Grimaldo, Mendoza, & Reyes, 2016). Esto se ha convertido en una problemática, ya que existen variables que influyen cada año y se requiere ajustar la proyección estimada para lograr una alta credibilidad y confiabilidad en los análisis (UPME, 2023; Grimaldo, 2013). En este contexto, la aplicación de técnicas de Machine Learning (ML) ha demostrado ser efectiva para mejorar la predicción de la demanda energética a nivel global, pero su implementación enfrenta desafíos críticos como la falta de estandarización de datos, la escasez de capacidades técnicas locales y la resistencia a migrar de modelos tradicionales a sistemas basados en IA (Tabares & Velásquez, 2021; BID & UPME, 2024). Si bien estos modelos han sido utilizados en áreas como la predicción de fallos en la red, diagnóstico, predicción de potencia y precios (Medina & García, 2005, p.16), su adopción en América Latina requiere superar brechas estructurales, como la fragmentación de datos entre actores del sector y la limitada inversión en infraestructura digital (Ortega-Díaz et al., 2023). Para que la integración de ML sea orgánica, se necesitan políticas públicas que fomenten la interoperabilidad de sistemas, la capacitación de talento especializado y la creación de repositorios de datos abiertos que permitan entrenar algoritmos con información local precisa (IEA, 2023; Cortázar & Villanueva, 2025).

La literatura y los avances en modelos predictivos de demanda energética en Colombia presentan limitaciones significativas, sustentadas en la predominancia de metodologías

tradicionales como las proyecciones estadísticas de la UPME (2024), que estiman un crecimiento anual de la demanda entre 1,16% y 4,79% hasta 2037 mediante series temporales y regresiones, pero sin incorporar sistemáticamente técnicas de inteligencia artificial (IA), lo que refleja un rezago frente a estándares globales. Aunque existen estudios académicos como los de Garzón Medina y Marulanda García (2017), que emplean modelos aditivos con errores de hasta el 55% en predicciones de largo plazo, o iniciativas recientes como el trabajo de Castellanos y Ardila sobre la Predicción de la demanda energética en el departamento de Boyacá Colombia, empleando técnicas de Deep Learning (Castellanos Camargo & Ardila Torres, 2023) en Boyacá, que aplica redes neuronales profundas (deep learning), estos esfuerzos son fragmentados y carecen de escalamiento nacional, según análisis del BID y Minenergía (2024), que destacan la necesidad de modernizar la planificación energética. Además, investigaciones como las de Ortega y Diaz, (2023) identifican falta de protocolos unificados para validar modelos, mientras el DNP (2023) señala que la fragmentación de datos entre actores del sector obstaculiza el desarrollo de algoritmos robustos. Si bien emergen casos puntuales, como los modelos LSTM de la Universidad de Antioquia para pronósticos horarios con errores inferiores al 15%, persiste una desconexión entre la academia y las entidades reguladoras, lo que evidencia un panorama con avances incipientes pero insuficientes, marcado por la escasez de estudios consolidados y la ausencia de políticas que fomenten la adopción orgánica de IA en la gestión energética nacional. Se considera así que este análisis es pertinente para abordar esta problemática nacional y para ayudar a determinar cómo se podría aprovechar los beneficios del aprendizaje automático en la predicción de la demanda energética nacional, facilitando la toma de decisiones informadas y una mejor planeación de los recursos (Medina & García, 2005; Grimaldo, 2013). A nivel de

Colombia podría representar una alternativa apropiada para mejorar la precisión y eficiencia en la gestión del suministro energético de manera considerable.

La realización de esta monografía tiene como objetivo generar un impacto significativo al arrojar luz sobre la aplicación del aprendizaje automático en la predicción de la demanda energética a nivel nacional. Este análisis es particularmente relevante en la actualidad, ya que aprovecha las herramientas y beneficios del aprendizaje automático para profundizar en sus ventajas en el sector energético. Los hallazgos de este estudio pueden convertirse en un insumo crucial para el sector eléctrico, facilitando la toma de decisiones informadas y mejorando la planeación, aprovechamiento y optimización de los recursos tanto a nivel regional como nacional (Medina & García, 2005; Grimaldo, 2013). La relevancia de este trabajo radica en su capacidad para proporcionar soluciones innovadoras y precisas para la predicción de la demanda energética, lo cual es esencial para la gestión eficiente del suministro energético en Colombia.

Objetivos

Objetivo General

Evaluar el potencial del uso de técnicas de Machine Learning para la predicción de la demanda energética en Colombia, mediante la revisión de experiencias internacionales, la identificación de modelos existentes y la determinación de su aplicabilidad al contexto nacional.

Objetivos Específicos

Revisar experiencias internacionales sobre el uso de Machine Learning en la predicción de la demanda energética, destacando enfoques, metodologías y resultados obtenidos.

Clasificar los principales algoritmos de Machine Learning aplicados a la predicción de demanda energética, analizando sus características, ventajas y limitaciones.

Analizar la aplicabilidad de estos modelos en el contexto colombiano, considerando las condiciones del sector energético y los posibles beneficios de su implementación.

Marco Conceptual

Inteligencia Artificial

La inteligencia artificial (IA) es considerada una rama de las ciencias de la computación que ha despertado un gran interés en la era moderna, lo anterior gracias a su diverso campo de acción y sus múltiples aplicaciones en diversos sectores. La búsqueda a gran escala de mecanismos que ayuden y faciliten la comprensión y simulación de la inteligencia humana ha permitido realizar modelos y simulaciones, obteniendo grandes logros y avances en este particular, generando un gran interés en el sector científico para elegir esta área como nuevo campo de investigación y desarrollo (Iniciativa Latinoamericana de Libros de Texto Abiertos (LATIn), 2014).

En el ámbito energético, la gestión eficiente y sostenible de los recursos es crucial para satisfacer la creciente demanda global. La transición hacia un modelo energético más limpio y eficiente implica la integración de fuentes renovables como la solar y la eólica, lo que requiere sistemas de gestión avanzados para equilibrar la oferta y la demanda (Cuerva Energía, 2024). Además, la optimización del consumo energético y la reducción de emisiones son objetivos prioritarios en la industria, donde la tecnología juega un papel clave.

Actualmente la IA se ha extendido ampliamente en diversas áreas de investigación y busca integrar diferentes métodos, modelos y técnicas a gran escala, buscando explotar al máximo las ventajas de cada una de estas, en una gran cantidad de campos del conocimiento como lo son; la medicina, biología, robótica, ingeniería, economía, astronomía, educación etc. (LATIn 2014)

La inteligencia artificial (IA) busca imitar los procesos y aspectos de la inteligencia humana para ser aplicados a las máquinas. Los procesos que se llevan a cabo en el cerebro

humano pueden ser analizados a un nivel de abstracción dado, como procesos computacionales de algún tipo. El propósito de la IA es hacer computacional el conocimiento y aprendizaje humano, (Hardy, T. 2001; Maisueche 2019). La inteligencia artificial (IA) busca imitar los procesos de la inteligencia humana para aplicarlos a las máquinas, analizando y procesando grandes volúmenes de datos para mejorar la eficiencia y la toma de decisiones (Hardy, T., 2001; Maisueche, 2019).

En este contexto, la inteligencia artificial (IA) ha emergido como una herramienta fundamental para transformar e impulsar el sector energético. En este ámbito, la IA se utiliza para optimizar redes eléctricas inteligentes, predecir la demanda energética, y mejorar la integración de energías renovables, lo que permite una gestión más sostenible y eficiente del suministro energético (Novaluz, 2025; Cuerva Energía, 2024).

Machine Learning (Aprendizaje Automático)

El aprendizaje automático es una rama de la inteligencia artificial cuyo fin es dotar a una máquina, a través de algoritmos, de la capacidad de entrenar y aprender a partir de datos, sin ser explícitamente programada, imitando la capacidad que tienen las personas de aprender mediante ejemplos, sin recurrir a formulas ni reglas entre las variables y posibilitando a su vez al término del entrenamiento, un modelo que permite la generalización; es decir la obtención de resultados en nuevas situaciones no conocidas durante el aprendizaje.

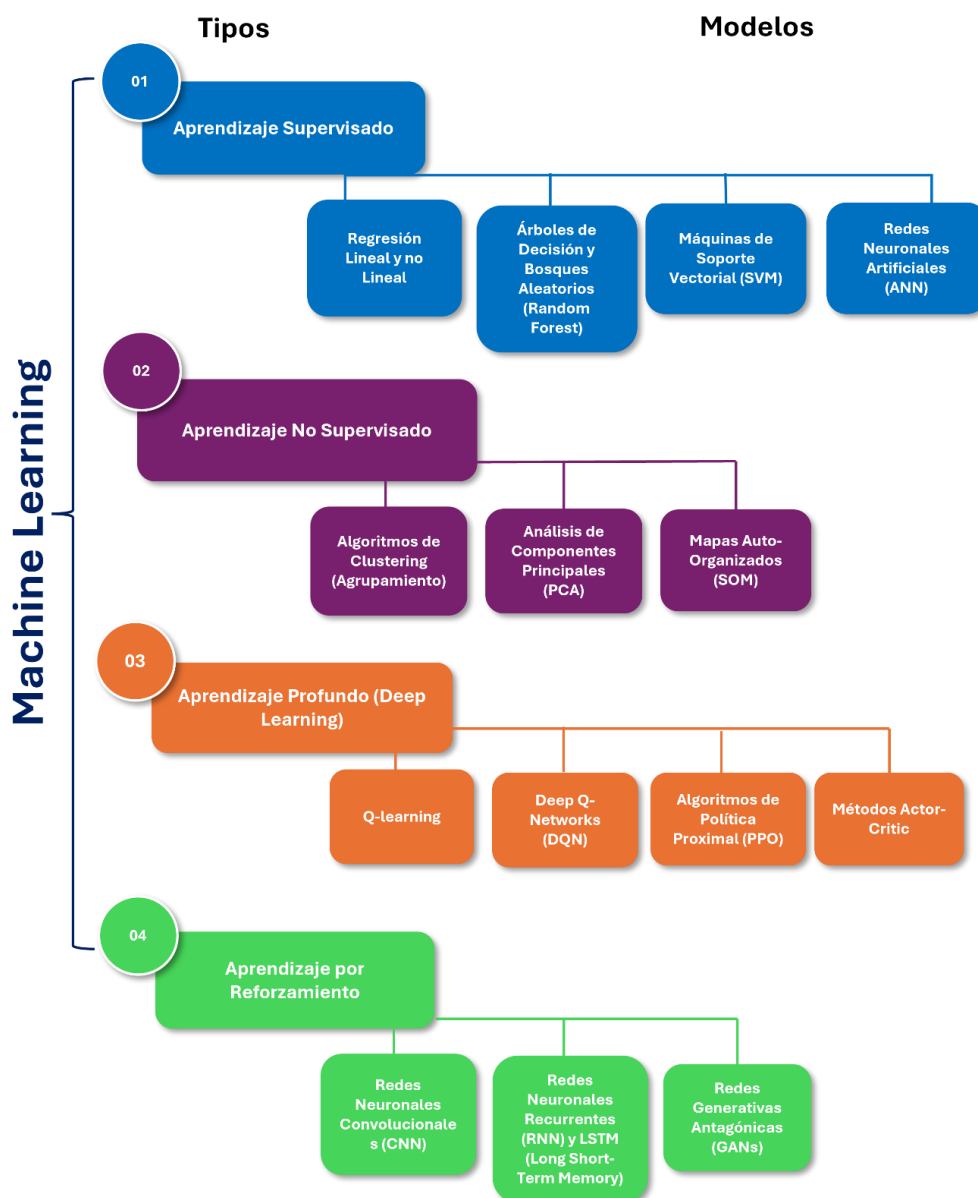
El aprendizaje automático como rama importante de la inteligencia artificial, representa en cierta medida el presente y el futuro de nuestra forma de entender el mundo. El aprendizaje automático conocido en inglés como; Machine Learning (ML), es la capacidad o habilidad que se ha incorporado en las maquinas computacionales para que, a través de algoritmos especializados puedan imitar el aprendizaje humano, estos algoritmos generalizan

comportamientos en base a ejemplos proporcionados. Mediante el entrenamiento, van desarrollando la capacidad de mejorar los procesos con cada iteración a medida que el sistema es alimentado con datos e información, (Vélix 2020).

El aprendizaje automático puede definirse en cuatro grandes tipos de algoritmos o variantes principales como los son, ver figura 1:

Figura 1

Tipos de Aprendizaje y Modelos de Machine Learning



1. Aprendizaje Supervisado: Utiliza conjuntos de datos etiquetados para que los patrones puedan ser detectados y se puedan utilizar para etiquetar nuevos conjuntos de información.
2. Aprendizaje no Supervisado: Utiliza conjuntos de datos no etiquetados y por lo tanto la única forma de ser acomodado es mediante la revisión y análisis de diferencias y similitudes que faciliten la diferenciación.
3. Aprendizaje de Reforzado: Utiliza datos no etiquetados, pero después de realizar varias acciones el sistema será retroalimentado mediante actualizaciones.
4. Aprendizaje Profundo: Está inspirado en el funcionamiento del cerebro humano para extraer capacidades como visión, reconocimiento de patrones o control moto-sensorial, mediante el empleo de redes neuronales artificiales, (Cárdenas 2018; Maisueche 2019).

Marco Teórico

Inteligencia Artificial en el Sector Energético

En la actualidad, el uso de la Inteligencia Artificial (IA) se ha extendido a muchas áreas del conocimiento humano entre ellos el sector energético, relacionados directamente con la mejora de la eficiencia en diferentes campos como lo son: El mantenimiento predictivo, la predicción de la demanda y la oferta, nuevos servicios y capacidades para los consumidores, tendencias del mercado etc. Lo anterior está orientado a gestionar y optimizar la energía de una manera más eficaz, conduciendo al ahorro energético y la reducción del impacto ambiental, (Vinicio, Gruezo-Valencia, 2022, (Inderwildi, Zhang, Wang, & Kraft, 2020). Teniendo en cuenta la aseveración de Padrón, (2015) la utilización de la energía eléctrica está presente en casi todas las actividades que se desarrollan en los países a partir de cierto desarrollo económico, se prevé para los próximos decenios un gran crecimiento del consumo eléctrico a nivel global.

Debido a la demanda de la nueva conciencia ambiental que está presente en la actualidad por los efectos adversos del cambio climático, se hace necesario una gestión de la energía más razonable, eficiente y adecuada, que permita o facilite la utilización del recurso energético de una manera más apropiada, como lo indican, Vinicio, Gruezo-Valencia, (2022) las técnicas de los sistemas inteligentes presentan cualidades que han tenido un impacto positivo en las diversas actividades que tiene relación con la eficiencia energética, (ENFORCE, 2010) .

Aprendizaje Automático en la Predicción de la Demanda Energética

La planificación adecuada de la demanda energética es fundamental para anticipar y gestionar de una manera responsable el recurso energético optimizando su uso y garantizando el servicio al consumidor final, con respecto a esto, Sánchez Durán (2020), indica que, la planificación de la demanda energética es clave para anticipar y gestionar una transición sostenible

a lo largo de este siglo XXI. En este sentido los avances y desarrollos tecnológicos como los algoritmos de predicción de la demanda, son una herramienta de gran relevancia en “Energy Forecasting” (Pronóstico energético) un concepto que se ha venido popularizando en el mundo basado principalmente en la recolección y tratamiento de datos (Sánchez Durán, 2020)

Los modelos predictivos en el sector energético se fundamentan básicamente, en la necesidad de planificar el suministro de energía para satisfacer la demanda. Estos modelos son esenciales para la formulación de políticas y el desarrollo del sector energético, ya que permiten a las empresas y reguladores tomar decisiones informadas sobre la producción y distribución de energía (Vinicio, Gruezo-Valencia, 2022).

La selección de un método de pronóstico depende de la disponibilidad de datos y los objetivos específicos de la herramienta de planificación (Kumar & Monjur, 2018). Algunos de los métodos más comunes incluyen:

- Red Neuronal Artificial (RNA): Utiliza algoritmos inspirados en el cerebro humano para analizar patrones complejos en los datos históricos de consumo energético.
- Máquina de Vectores de Soporte (SVM): Clasifica y predice valores basándose en la separación óptima de los datos.
- Promedio Móvil Integrado Autorregresivo (ARIMA): Analiza tendencias y estacionalidad en series temporales para predecir futuras demandas.
- Regresión Lineal (LR): Establece relaciones lineales entre variables para predecir valores futuros.
- Algoritmo Genético (GA) y Optimización de Enjambre de Partículas (PSO): Utilizan principios evolutivos y de búsqueda para optimizar parámetros de los modelos predictivos.

- Predicción Gris (GM): Se utiliza para series temporales con poca información histórica.

Estos modelos permiten a las empresas energéticas anticipar la demanda y ajustar su producción y distribución en consecuencia, mejorando la eficiencia y reduciendo los costos. Kumar & Monjur (2018) resaltan que, en cuanto a la precisión, los métodos de inteligencia computacional (IC) demuestran un mejor desempeño que los estadísticos, en particular para parámetros con mayor variabilidad en los datos de origen. Además, los métodos híbridos ofrecen una mayor precisión que los independientes. Los métodos estadísticos se utilizan solo para el corto y mediano plazo, mientras que los métodos de inteligencia computacional (IC) son preferibles para todos los rangos de pronóstico temporal (corto, mediano y largo plazo).

- 1) Previsión a corto plazo: Son generalmente inferiores a los tres meses, son usados especialmente para la programación de actividades, trabajos y tareas de corta duración.
- 2) Previsión a medio plazo: Su plazo está entre tres meses a tres años. Son los más comunes y son usados en la planificación de las ventas, de la producción y del presupuesto.
- 3) Previsiones a largo plazo: Sus periodos son superiores a los tres años. Estas tienen un impacto sobre la dirección de los sistemas de producción y que a su vez deben ser consistentes con las metas a largo plazo de las organizaciones, (Grimaldo, 2013).

Lo anterior ayuda sustancialmente a los actores principales que intervienen en el proceso como lo indica Grimaldo, (2013)

- 1) En los generadores de energía les va a permitir o facilitar localizar los periodos para los cuales habrá faltante o excesos de capacidad de generación, y así poder planificar de manera más precisa las inversiones de expansión del sistema, estas inversiones generalmente son proyectos de gran tiempo de ejecución y la entrada a tiempo puede generar mayor confiabilidad

al sistema.

2) En los distribuidores y transmisores permite definir con mayor margen de precisión los mantenimientos y a la programación de la expansión del sistema de transmisión.

3) En los comercializadores, es determinante para el estudio del comportamiento del mercado y generar los planes operativos que se requieran, que a su vez ayudaran al operador para programar la operación de las generadores minimizando los ajustes de entrada de operación evitando sobrecostos en la producción.

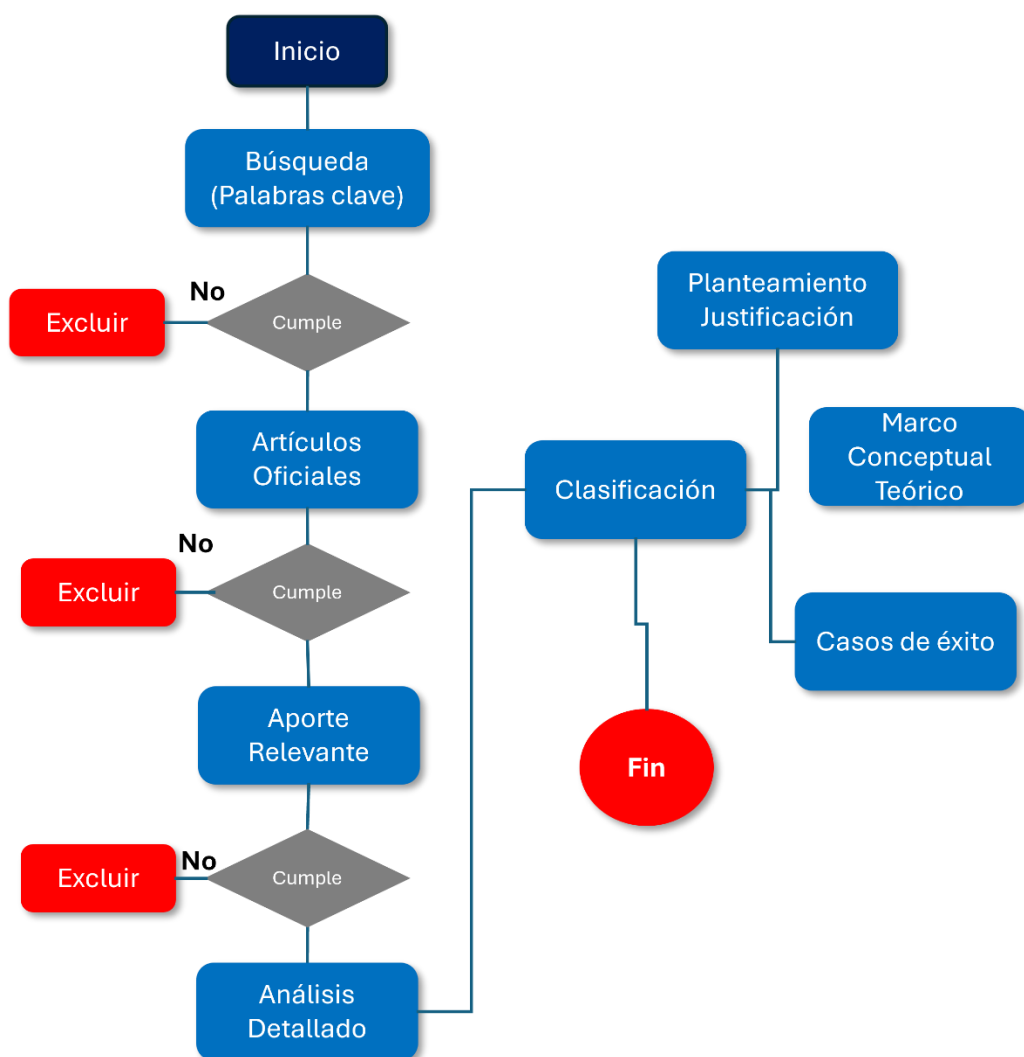
Como ya se mencionó el Machine Learning puede aportar en gran medida en muchas áreas del sector energético entre ellas a la predicción de la demanda, facilitando la toma de decisiones informadas y la planeación estratégica en el corto, mediano y largo plazo.

Metodología

La metodología utilizada en este estudio se basó en una revisión de literatura sistemática y de un análisis cualitativo de diversas fuentes como lo son; investigaciones, artículos científicos y estudios de caso internacionales, sobre la aplicación de Machine Learning en la predicción de la demanda energética. A continuación, se presenta un diagrama de flujo que ilustra el proceso de inclusión y exclusión realizado.

Figura 2

Diagrama del Proceso Inclusión/Exclusión de la Bibliografía



Este proceso metodológico se desarrolló en varias etapas complementarias que permitieron abordar el estudio de manera estructurada, pero flexible. En primer lugar, se llevó a cabo una búsqueda y selección rigurosa de fuentes bibliográficas y referencias relevantes. Esta revisión incluyó estudios publicados en bases de datos académicas, artículos científicos, informes de instituciones energéticas internacionales y publicaciones especializadas en Machine Learning y energía. Para ello, se utilizaron palabras clave como “machine learning”, “energy demand forecasting”, “predicción de la demanda energética”, “algoritmos de predicción energética” y “demanda energética”, entre otras.

Durante esta fase, se priorizaron los estudios que presentaban aplicaciones concretas y actuales de técnicas de Machine Learning en el contexto energético. Como criterio de exclusión, se descartaron aquellas fuentes que abordaban el tema de manera superficial, sin resultados verificables o sin una aplicación directa a la predicción de la demanda energética. La selección final se centró en trabajos que aportaran valor técnico y conceptual al objetivo de la monografía. En total, se revisaron algo más (80) artículos, de los cuales (45) fueron seleccionados para el análisis detallado.

Posteriormente, se identificaron y analizaron casos exitosos a nivel internacional que mostraban la aplicación efectiva de técnicas de Machine Learning en la predicción de la demanda energética. Entre los países estudiados se encuentran especialmente Turquía y Arabia Saudita de los cuales cuentan con sistemas avanzados de gestión energética y sus casos de éxito aportan bastante al caso de estudio ya planteado. Estos casos abarcan una diversidad de enfoques, incluyendo modelos de ensamble, redes neuronales y técnicas híbridas, utilizados para optimizar tanto el consumo como la planificación energética.

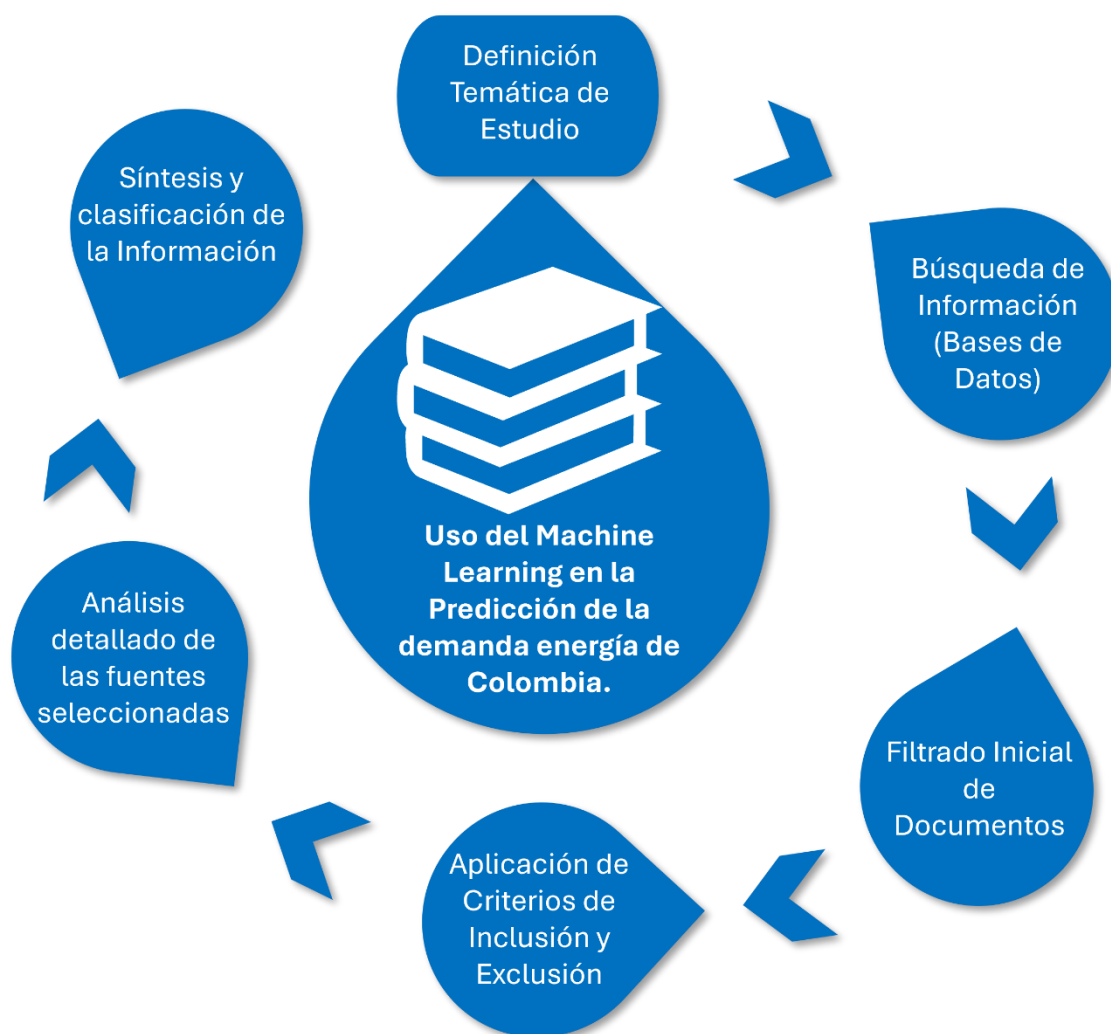
A continuación, se realizó un análisis comparativo de los distintos modelos y enfoques de Machine Learning identificados en la literatura. Este análisis permitió observar sus fortalezas y limitaciones, considerando aspectos como la precisión de las predicciones, la integración de energías renovables y la capacidad de respuesta ante variaciones en la demanda. Entre los factores que influenciaron la efectividad de estos modelos, se destacaron la calidad de los datos, la elección adecuada de algoritmos y las condiciones particulares de cada mercado energético.

Con base en estos casos y modelos, se extrajeron recomendaciones específicas para Colombia, orientadas a la posible adopción de tecnologías similares en el ámbito nacional. Estas recomendaciones tomaron en cuenta elementos clave como la infraestructura energética existente, la disponibilidad de datos confiables y las características geográficas del país, con el propósito de adaptar las mejores prácticas internacionales al contexto colombiano.

Finalmente, se sintetizaron los hallazgos más relevantes de la revisión documental, resaltando tanto los beneficios como los desafíos de implementar técnicas de Machine Learning en la predicción de la demanda energética. Este enfoque metodológico permitió construir un panorama amplio y detallado sobre el estado actual del tema, basado en el análisis cualitativo de estudios previos y experiencias exitosas en otros países. Cabe señalar que no se realizaron experimentos ni recolección de nuevos datos; el trabajo se centró exclusivamente en el estudio de antecedentes documentados y en la extracción de conclusiones aplicables al caso colombiano. A continuación, se presenta un diagrama que ilustra de manera general el proceso de revisión de la literatura.

Figura 3

Diagrama Global de Revisión de la Bibliografía



Casos de Éxito y Hallazgos Clave en la Aplicación de Machine Learning para la Predicción de la Demanda

La implementación de Machine Learning (ML) en la predicción de la demanda energética ha mostrado resultados prometedores a nivel global, y se cuentan con varios estudios que han documentado casos de éxito en este particular.

La predicción de la demanda energética es un desafío crítico en el sector energético global, ya que requiere una precisión alta para garantizar la eficiencia en la producción y distribución de energía. En los últimos años, el uso de técnicas de Machine Learning e Inteligencia Artificial ha revolucionado este campo, permitiendo mejorar significativamente la precisión de las predicciones. Estas tecnologías han sido aplicadas en otras regiones del mundo, demostrando su capacidad para optimizar la gestión energética y reducir los costos operativos. A continuación, se presentan los casos de éxito internacionales y hallazgos más relevantes que evidencian el potencial de las técnicas de Machine Learning en la predicción de la demanda energética, así como los factores clave que influyen en su implementación exitosa.

1) Enfoques de Ensemble para la Predicción de la Demanda Energética en Turquía. El estudio, *Ensemble Machine Learning Approaches for Prediction of Türkiye's Energy Demand (2021)* demostró que los enfoques de Machine Learning de ensamblaje, como las redes neuronales y las máquinas de soporte vectorial, ofrecieron predicciones de alta precisión para la demanda energética en Turquía. En este estudio, los modelos de ensemble combinaban varios algoritmos de ML para mejorar la precisión en las predicciones de la demanda energética a corto, mediano y largo plazo. Esto les permitió a los planificadores energéticos ajustar de manera más precisa las políticas de producción y distribución de electricidad.

2) Predicción de Energía en Sistemas de Gestión Inteligente de Edificios. En el estudio, *Machine Learning-Based Energy Use Prediction for the Smart Building Energy Management System (2020)*, se implementó un sistema de predicción de la demanda energética para edificios inteligentes en Indonesia, usando técnicas de Machine Learning. Esta investigación demostró que las redes neuronales y los modelos de regresión proporcionaban una predicción precisa del consumo de energía de edificios comerciales, permitiendo un manejo más eficiente de los recursos energéticos, optimizando la calefacción, ventilación y aire acondicionado (HVAC) en tiempo real.

3) Predicción de la Demanda Energética para la Generación de Energía Renovable. En el artículo, *Machine Learning Based Renewable Energy Generation and Energy Consumption Forecasting (2021)*. Se presenta un enfoque interesante con respecto al uso de Machine Learning para la predicción de la generación de energía renovable, en este estudio realizado en India, se abordó la predicción tanto del consumo de energía como de la producción de energía renovable (solar y eólica) mediante modelos de aprendizaje automático, lo que optimiza la integración de estas fuentes en las redes eléctricas tradicionales y mejora la eficiencia operativa. Se utilizó una red neuronal convolucional (CNN) para la predicción de la generación de energía y una red neuronal de memoria a largo plazo (LSTM) para la predicción del consumo energético. Los resultados mostraron una alta precisión en las predicciones, con errores mínimos en la estimación de la generación y el consumo de energía.

4) Predicción de la Demanda Energética en el Sector del Transporte de Arabia Saudita. En, *Energy Demand of the Road Transport Sector of Saudi Arabia - Application of a Causality-Based Machine Learning Model (2020)*, se aplicaron modelos causales de ML para prever la demanda energética en el sector del transporte en Arabia Saudita. Este enfoque ayudó a

prever las necesidades energéticas del sector del transporte, lo cual es crucial para la planificación del uso de combustibles y la transición hacia soluciones energéticas más sostenibles. Para este caso de estudio se utilizó un modelo de Red Neuronal Artificial (ANN) para modelar la relación no lineal entre los factores socioeconómicos y la demanda energética. Y el modelo de Regresión de Soporte Vectorial (SVR) para capturar patrones complejos y no lineales en los datos, proporcionando una alternativa robusta a la ANN. Los hallazgos concluyeron que el modelo SVR es más adecuado para predecir la demanda energética en el sector del transporte en Arabia Saudita, lo que puede ayudar en la planificación y formulación de políticas para una transición energética más sostenible.

5) Predicción a Corto Plazo de la Demanda Energética con Machine Learning. Un estudio significativo en *Edge-Based Short-Term Energy Demand Prediction (2021)* investigó la predicción de la demanda energética a corto plazo usando técnicas de ML basadas en "edge computing" explorando la eficacia de la predicción de la demanda energética a corto plazo. El modelo principal utilizado fue el Temporal Fusion Transformer (TFT), una arquitectura avanzada diseñada para series temporales que permitió capturar relaciones temporales complejas y realizar predicciones precisas directamente en dispositivos locales. Esta implementación permitió reducir la latencia en la toma de decisiones y mejorar la eficiencia en la gestión energética en tiempo real. Los resultados mostraron una alta precisión predictiva, con un error absoluto medio (MAE) de 68 kWh, un RMSE de 86 kWh y un MAPE del 87,88 %, lo que indica una capacidad robusta para prever el consumo energético en intervalos de 10 minutos. Este enfoque representa un avance clave para optimizar el suministro eléctrico en redes inteligentes, demostrando que la combinación de edge computing con modelos como TFT puede ser una solución efectiva para mejorar la eficiencia operativa del sistema energético.

A continuación, se presenta una tabla comparativa de los modelos de Machine Learning utilizados en los casos de éxitos internacionales que se acaban de mencionar, ver tabla 1.

Tabla 1

Modelos de Machine Learning Utilizados

Estudio	Modelo de ML Utilizado	Aplicación	Resultados Clave
Ensemble machine learning approaches for prediction of türkiye's energy demand (2021)	Modelos de Ensemble (Redes Neuronales, Máquinas de Soporte Vectorial)	Predicción de la demanda energética en Turquía	Predicciones de alta precisión para la demanda energética a corto, mediano y largo plazo, mejorando la planificación de producción y distribución.
Machine learning-based energy use prediction for the smart building energy management system (2020)	Redes Neuronales, Modelos de Regresión	Predicción del consumo energético en edificios inteligentes	Optimización del consumo energético en tiempo real, mejorando la eficiencia en la gestión de recursos como HVAC.
Machine learning based renewable energy generation and energy consumption forecasting (2021)	Modelos de Machine Learning (redes neuronales y algoritmos de regresión)	Predicción de generación de energía renovable (solar y eólica) y consumo	Mejora de la integración de energías renovables en las redes eléctricas y optimización de la eficiencia operativa.

Energy demand of the road transport sector of saudi arabia - application of a causality-based machine learning model (2020)	Modelos Causales de Machine Learning (Redes Neuronales, Algoritmos de Regresión)	Predicción de la demanda energética en el sector del transporte	Predicción precisa de la demanda energética del sector del transporte, facilitando la transición a soluciones energéticas más sostenibles.
Edge-based short-term energy demand prediction (2021)	Redes Neuronales, Máquinas de Soporte Vectorial, Edge Computing	Predicción de la demanda energética a corto plazo	Predicciones precisas a corto plazo, optimizando el suministro en tiempo real para la gestión eficiente de la energía.

Factores que Influyen en la Precisión de las Predicciones de la Demanda

La eficacia de los modelos de Machine Learning en la predicción de la demanda energética depende de varios factores que, según el análisis realizado, son comunes en la mayoría de los estudios internacionales revisados:

1) **Calidad y Disponibilidad de los Datos.** La calidad de los datos utilizados en el entrenamiento de los modelos es un factor determinante. Como señala el estudio *Influencing Factors Evaluation of Machine Learning-Based Energy Consumption Prediction (2020)*, una mayor precisión en la predicción depende de la calidad de los datos históricos con respecto al consumo energético, las condiciones climáticas, los patrones de comportamiento del consumidor y los datos económicos. El estudio empleó técnicas de limpieza y preprocesamiento de datos para mejorar su calidad antes de entrenar los modelos. Como beneficio, se observó que la precisión de las predicciones aumentó significativamente cuando se utilizaron datos más completos y actualizados, permitiendo una mejor planificación energética y reducción de errores en la estimación de la demanda.

2) **Selección de Algoritmos Apropriados.** El tipo de algoritmo utilizado influye directamente en la precisión de las predicciones. En *Energy Demand Forecasting in Seven Sectors by an Optimization Model Based on Machine Learning Algorithms (2021)*, se realizó una comparación entre diferentes algoritmos de Machine Learning, incluyendo redes neuronales profundas y métodos de Ensemble Learning, aplicados a siete sectores energéticos. El estudio implementó un proceso de optimización para seleccionar el mejor modelo en cada caso. El beneficio principal fue una mejora en la capacidad de generalización y precisión de las predicciones, superando a los métodos estadísticos tradicionales y facilitando la toma de decisiones en la gestión de la demanda energética.

3) Condiciones Locales y Contexto del Mercado Energético. En la aplicación de Machine Learning para la predicción de la demanda energética, es importante considerar las características del mercado energético local. En *Energy Demand Prediction Based on Deep Learning Techniques (2020)*, se realizó un estudio de caso en una región específica, integrando variables locales como infraestructura energética, patrones de consumo y eventos imprevistos (olas de calor, cambios económicos). El estudio utilizó redes neuronales profundas entrenadas con datos locales y simulaciones de escenarios climáticos. El beneficio obtenido fue una mayor adaptabilidad del modelo a las condiciones reales del mercado, permitiendo respuestas más rápidas y precisas ante variaciones inesperadas en la demanda.

4) Modelos Híbridos y Técnicas Combinadas. El uso de modelos híbridos, que combinan varias técnicas de Machine Learning, ha demostrado ser más efectivo que los enfoques individuales. En el artículo *Predicting Energy Demand in Semi-Remote Arctic Locations (2020)*, se realizó la implementación de un modelo híbrido que combinó redes neuronales y algoritmos genéticos para predecir la demanda energética en una región ártica remota. El proceso incluyó la integración de datos meteorológicos extremos y patrones de consumo locales. El beneficio principal fue una mejora significativa en la precisión y adaptabilidad de las predicciones, permitiendo optimizar el suministro energético en condiciones adversas y reducir costos operativos.

5) Contexto Global y Marco Regulatorio. El Acuerdo de París (2015), ratificado por 195 países, establece metas críticas para descarbonizar el sector energético, limitando el calentamiento global a 1.5-2°C. Este marco influye directamente en las proyecciones de demanda, ya que requiere:

- Triplicar la capacidad renovable global para 2030 (11,000 GW).

- Reducir emisiones del sector eléctrico en un 80-100% para 2050.
- Inversiones anuales en energías limpias de \$4.5 billones para 2030.

Estos objetivos están reconfigurando los mercados energéticos. Por ejemplo, la fijación de precios al carbono (usada en 46 países) penaliza plantas de carbón y gas, alterando los patrones de generación y demanda. Modelos de la *Resources for the Future* proyectan que un impuesto de \$28/ton CO₂ aumentaría precios eléctricos en 0.7 centavos/kWh para 2035, con impactos diferenciados en hogares y empresas.

Adicionalmente, este marco ha impulsado numerosos estudios y políticas que integran variables climáticas en la predicción de la demanda energética. Por ejemplo, la Agencia Internacional de Energía (IEA) realiza análisis anuales utilizando modelos que incorporan escenarios de reducción de emisiones y transición tecnológica, evaluando el impacto de políticas climáticas en la demanda y generación de energía. Los beneficios de estos estudios incluyen la identificación de rutas óptimas para alcanzar los objetivos climáticos, la estimación de inversiones necesarias y la promoción de una transición energética justa y sostenible.

A partir de los casos de éxito ya mencionados, se puede identificar los siguientes hallazgos clave que respaldan la viabilidad de la aplicación de Machine Learning en la predicción de la demanda energética en Colombia:

- 1) Mejoras en la Precisión de las Predicciones: Los modelos de Machine Learning, especialmente los de redes neuronales profundas y los enfoques de ensamble, han mostrado una mayor precisión en la predicción de la demanda energética en comparación con los métodos tradicionales, lo que permitiría una mejor planificación y gestión del suministro energético.

2) Optimización del Consumo Energético: La aplicación de estos modelos no solo permite predecir la demanda energética, sino también optimizar el consumo energético en tiempo real, lo que sería de gran beneficio para los sectores industriales y residenciales en Colombia.

3) Facilitación de la Integración de Energías Renovables: Los modelos de Machine Learning también pueden mejorar la integración de energías renovables en la red eléctrica, esto es crucial y de gran importancia para el futuro energético de Colombia, dado que es un país con una creciente importancia con respecto a las fuentes de energía renovables.

Discusión

Esta investigación tuvo como objetivo principal explorar el potencial del uso de técnicas de Machine Learning (ML) para la predicción de la demanda energética en Colombia, a partir de la revisión de literatura sobre experiencias internacionales. Los hallazgos derivados del análisis de casos internacionales como Turquía, Arabia Saudita, India e Indonesia indican que las tecnologías basadas en ML han mostrado mejoras significativas en la precisión de las predicciones energéticas. Estas tecnologías también han facilitado una gestión más eficiente de los recursos energéticos, como lo sugiere el Plan de Transición Energética (UPME, 2023) para Colombia.

En comparación con los métodos tradicionales de predicción, los modelos basados en ML, especialmente aquellos que emplean enfoques híbridos o técnicas de ensamble como redes neuronales profundas y máquinas de soporte vectorial, ofrecen ventajas evidentes en cuanto a su capacidad de adaptación a escenarios dinámicos y variados. Esta flexibilidad es particularmente relevante para Colombia, dada la predominancia de su matriz energética hídrica (68%, según Corficolombiana, 2021), lo que la hace vulnerable a eventos climáticos extremos como El Niño.

Los resultados de esta revisión permiten identificar varias áreas de convergencia entre las experiencias internacionales y las necesidades del sistema energético colombiano. Por ejemplo, los modelos causales de ML utilizados en Arabia Saudita para prever la demanda en el sector del transporte tienen paralelismos con los desafíos que Colombia enfrentará, especialmente debido a la electrificación del transporte y al crecimiento económico proyectado. Además, los estudios que integran variables climáticas y simulan escenarios de alta incertidumbre (como los basados en RCP 8.5) proporcionan una perspectiva valiosa para Colombia, considerando la alta sensibilidad de la generación hidroeléctrica al cambio climático.

Desde esta perspectiva, la aplicabilidad de estas técnicas en Colombia parece ser viable, aunque requiere de una consideración cuidadosa de los factores locales. Es fundamental abordar algunos aspectos críticos para la implementación exitosa de estos modelos. En primer lugar, fortalecer la infraestructura de datos es crucial. La calidad y disponibilidad de datos energéticos, meteorológicos y socioeconómicos son esenciales para la efectividad de los modelos de ML, como lo establece el Marco para el Desarrollo de una Estrategia de Digitalización (UPME, 2023) en su enfoque en la estandarización de datos para sistemas predictivos. La recopilación sistemática, así como la creación de sistemas robustos para el almacenamiento, procesamiento y actualización de grandes volúmenes de información, es un paso necesario, tal como lo demuestra la plataforma Intégrame del Ministerio de Minas y Energía, que integra 60 indicadores mediante servicios en la nube para optimizar la toma de decisiones.

En segundo lugar, la formación de talento humano especializado en ciencia de datos y ML en el contexto energético es fundamental. La experiencia internacional sugiere que el éxito en la adopción de estas tecnologías está estrechamente vinculado a la capacidad técnica de los equipos. Esto subraya la necesidad de una formación adecuada que capacite a los profesionales locales en herramientas y metodologías validadas, como las incluidas en los lineamientos estratégicos para IA en el sector eléctrico colombiano

Otro aspecto relevante es la necesidad de una articulación institucional tanto a nivel nacional como internacional. Colombia puede beneficiarse significativamente al adaptar metodologías probadas, como las recomendadas por la CEPAL (2015) para la integración de políticas energéticas regionales, siempre que se ajusten a las realidades locales. La cooperación con instituciones académicas, como los modelos de participación territorial propuestos en la Estrategia de Desarrollo y Relacionamiento Territorial del Sector Minero-Energético

(MinEnergía, 2022), podría acelerar la adopción tecnológica mediante mecanismos de diálogo recíproco entre actores nacionales y territoriales. Adicionalmente, iniciativas como el Plan de Transición Energética Justa (MinEnergía, 2023) destacan la necesidad de coordinar con centros internacionales para desarrollar marcos normativos adaptables a contextos heterogéneos.

En cuanto a los desafíos que enfrenta Colombia, la heterogeneidad territorial, evidenciada en las brechas de cobertura energética en La Guajira y Vichada (menos del 60%, según Sistema de Información Eléctrico Colombiano (SIEL), 2020), exige modelos de alta resolución espacial. Esto requiere infraestructura especializada, como la plataforma Intégrame del Ministerio de Minas y Energía, que centraliza datos para optimizar decisiones en zonas apartadas. Además, la infraestructura tecnológica en regiones rurales, analizada por el Departamento Nacional de Planeación (DNP, 2023) en su diagnóstico de conectividad, limita el monitoreo en tiempo real, lo cual demanda inversiones prioritarias en redes de comunicación. Finalmente, el marco normativo debe actualizarse para fomentar la interoperabilidad, tal como propone el Plan de Digitalización Energética (UPME, 2023) mediante estándares de datos abiertos y esquemas de incentivos para innovación tecnológica.

Si bien los modelos de ML podrían mejorar la toma de decisiones en planificación energética, reducir costos operativos, como lo sugiere el Plan de Transición Energética Justa (MinEnergía, 2023) para optimizar redes con inteligencia artificial, facilitar la integración de renovables y aumentar la resiliencia climática, es importante destacar que estas son proyecciones basadas en estudios como el de Torres Sánchez (2023) en Antioquia, que validó modelos LSTM para pronósticos horarios, pero aún requieren escalamiento nacional. Este trabajo contribuye al cuerpo de conocimiento sobre IA en sistemas energéticos emergentes, tal como lo propone la

Revista Ingeniería y Competitividad (2024) en su análisis de modelos adaptados a la heterogeneidad colombiana.

Por último, es recomendable que las futuras investigaciones prioricen modelos híbridos entrenados con variables nacionales, siguiendo metodologías como las del Sistema de Información Eléctrico Colombiano (SIEL, 2023) para integrar datos climáticos del Instituto de Hidrología, Meteorología y Estudios Ambientales (IDEAM) y socioeconómicos del DANE. Se podría implementar estudios piloto en regiones estratégicas, como la propuesta de la UPME (2023) para validar modelos de ML en La Guajira y el Chocó, considerando sus patrones de demanda y vulnerabilidad climática.

Conclusiones

El presente estudio tuvo como objetivo general analizar el potencial del uso de técnicas de Machine Learning en la predicción de la demanda energética en Colombia, tomando como base la revisión de experiencias internacionales, modelos existentes y su posible aplicabilidad al contexto nacional. A partir del análisis realizado, se concluye que el uso de Machine Learning representa una herramienta poderosa para mejorar la precisión de los pronósticos energéticos y optimizar la gestión del sistema eléctrico. Las experiencias internacionales revisadas, (particularmente en países con contextos energéticos diversos como Turquía y Arabia Saudita) evidencian que estos modelos superan en desempeño a los métodos estadísticos tradicionales, permitiendo respuestas más ágiles, sostenibles y adaptadas a escenarios dinámicos y de alta incertidumbre.

En el caso colombiano, la aplicación de estas tecnologías resulta especialmente pertinente debido a la alta dependencia de fuentes hidroeléctricas, que hacen al sistema vulnerable frente a fenómenos climáticos como El Niño. En este contexto, el Machine Learning no solo ofrece mejoras en la precisión predictiva, sino que también puede contribuir a una planificación energética más resiliente, a la integración eficiente de fuentes renovables y a la reducción de costos operativos en el largo plazo. Sin embargo, también se identifican desafíos importantes que deben ser superados para una implementación exitosa. Entre ellos, destacan la necesidad de contar con datos de alta calidad y diversidad, una infraestructura tecnológica adecuada, y la formación de capital humano especializado en ciencia de datos en el contexto energético. La falta de estos elementos puede limitar el aprovechamiento del potencial del Machine Learning y dificultar su adopción efectiva en el corto y mediano plazo.

Asimismo, los casos de éxito internacionales subrayan la importancia de la colaboración interinstitucional e internacional para adaptar metodologías probadas a las particularidades del entorno local. El estudio demuestra que, si bien no existe un modelo único aplicable a todos los contextos, las lecciones aprendidas y buenas prácticas pueden servir de guía para el diseño de soluciones innovadoras adaptadas a las condiciones energéticas, sociales y climáticas de Colombia. En definitiva, este trabajo aporta una base conceptual y práctica que valida la viabilidad del uso de Machine Learning en la predicción de la demanda energética en Colombia. También pone de relieve la urgencia de avanzar hacia una transformación digital del sector energético, que permita responder a los desafíos de la transición energética, el cambio climático y el crecimiento de la demanda en un entorno cada vez más complejo y cambiante.

Referencias Bibliográficas

- Acuerdo de París*: Naciones Unidas, UNFCCC (unfccc.int/process-and-meetings/the-paris-agreement)
- Agencia Internacional de Energía (IEA): *World Energy Outlook* ([iea.org/reports/world-energy-outlook-2023](https://www.iea.org/reports/world-energy-outlook-2023))
- Alberto Maisueche Cuadrado (2019). *Utilización del Machine Learning en la industria 4.0*. (pp. 10-20)
- Atlas. (2024). *Panorama del consumo energético de Colombia 2024 a 2038*.
<https://www.atlas.com.co/panorama-del-consumo-energetico-de-colombia-2024-a-2038/>
- BBVA Research. (2021). Sector energético colombiano: retos y oportunidades.
- BID. (2023). Cinco cosas que debes saber sobre el sector energía en ALC.
- BID & UPME. (2024). Estudio para incluir las dimensiones energética y económica del cambio climático en la planificación del sector energético colombiano.
<https://www1.upme.gov.co>
- Castellanos Camargo, J. D. & Ardila Torres, N. S. (2023). *Predicción de la demanda energética en el departamento de Boyacá Colombia, empleando técnicas de Deep Learning (Trabajo de grado, Universidad de La Salle)*. Repositorio institucional de la Universidad de La Salle.
- Comisión Económica para América Latina y el Caribe. (2023). *Panorama energético de América Latina y el Caribe 2023*. CEPAL.
- Corficolombiana. (2021). Análisis de la matriz energética colombiana y vulnerabilidad climática. Corficolombiana S.A. <https://www.corficolombiana.com>

- Cortázar, D., & Villanueva, N. (2025). *La demanda energética como indicador de la industria en Colombia*. Informe de Política Monetaria, Banco de la República.
- Cuerva Energía*. (2024). Informe sobre Energías Renovables.
<https://www.cuervaenergia.com/informe>
- DNP (2023). Diagnóstico de infraestructura tecnológica rural. Departamento Nacional de Planeación.
- Dexma*. (2024). Predicción del Consumo Energético mediante Machine Learning.
- Du, K., Shao, S., & Yan, Z. (2021). Urban residential energy demand and rebound effect in China: A stochastic energy demand frontier approach. *Energy Journal*, 42(4), 175–193.
<https://doi.org/10.5547/01956574.42.4.kdu>
- ENFORCE. (2010). *Guía Práctica sobre Ahorro y Eficiencia Energética en Edificios*. Red de Auditores Energéticos de la Unión Europea (pp.60).
- Galvis Plata, J. (2022). *Modelo predictivo de consumos de energía eléctrica aplicando redes neuronales artificiales*. Trabajo de grado. Universidad Francisco de Paula Santander.
Recuperado de <https://repositorio.ufps.edu.co/handle/ufps/7116>
- Garriga Trillo, A. J. (2012). *Introducción al análisis de datos: formulario y tablas*. UNED - Universidad Nacional de Educación a Distancia (pp. 9-20).
- Grimaldo Guerrero (2012). *Modelo de Predicción de la Demanda Energía Eléctrica en Colombia por Regresiones Múltiples*. Universidad del Norte (pp. 10-30)
- Grimaldo Guerrero, Mendoza Becerra. Reyes Calle (2016). *Modelo para pronosticar la demanda de energía eléctrica utilizando el producto interno brutos sectoriales: Caso de Colombia* (pp. 1-17)
- Hardy, T. (2001). (IA: Inteligencia Artificial) POLIS, *Revista Latinoamericana*, (pp. 10-20)

- Hernández Sampieri, R., Mendoza Torres, C. P. (2018). *Metodología de la investigación: las rutas cuantitativa, cualitativa y mixta*. McGraw-Hill (pp. 41-50).
- Inderwildi, O., Zhang, C., Wang, X., & Kraft, M. (2020). The impact of intelligent cyberphysical systems on the decarbonization of energy. *Energy and Environmental Science*, 13.
- Instituto de Ingeniería del Conocimiento (IIC). (2023). Inteligencia Artificial y Big Data en el sector energético.
- IEA. (2023). Latin America Energy Outlook 2023.
- Informe Perspectiva Sectorial - *Energía*. (2023). Demanda de energía en Colombia 2022.
- Informe Perspectiva Sectorial - *Energía*. (2023). Corficolombiana.
<https://investigaciones.corficolombiana.com/documents/38211/0/Informe%20Sectorial%20Sector%20Electrico%2024012023%20VF.pdf>
- Juan Manuel Cárdenas (2018). *El machine Learning a través de los tiempos, y los aportes a la humanidad*. Universidad Libre, (pp. 1-10)
- Kumar, D., & Monjur, M. (2018). *Forecasting methods in energy planning models. Renewable and Sustainable Energy Reviews*. Volume 88. (pp. 297-325)
- LATIIn (2014). *Inteligencia Artificial. 1a ed. - Iniciativa Latinoamericana de Libros de Texto Abiertos*, (pp. 16-21)
- Medina Hurtado, Garcia Aguado (2005). *Predicción de demanda de energía en Colombia mediante un sistema de inferencia difuso neuronal* (pp. 1-25)
- MinEnergía (2022). Estrategia de Desarrollo y Relacionamiento Territorial del Sector Minero-Energético.
https://www.minenergia.gov.co/documents/9386/2._Estrategia_de_Desarrollo_y_Relacionamiento_Territorial_del_Sector_Minero-En_bZi4rr5.pdf.

MinEnergía (2023). Plan de Transición Energética Justa.

<https://www.minenergia.gov.co/documents/10180/23517/Plan+de+Transici%C3%B3n+Energ%C3%A9tica+Justa.pdf>.

Ministerio de Minas y Energía. (2021). Avances en la implementación de redes inteligentes y medición avanzada en Colombia. <https://www.minminas.gov.co>

OLADE. (2023). Panorama Energético de América Latina y el Caribe 2023.

Ortega-Díaz, L. et al. (2023). *Estrategias de predicción de consumo energético en edificaciones*. *TecnoLógicas*, 26(58), e2650. <https://revistas.itm.edu.co>

Padrón, S. (2015). *Inteligencia Artificial en la Operación de Redes Eléctricas. Aplicación a Peset, F. & Millán González, L. (2017). Ciencia abierta y gestión de datos de investigación (RDM)*. Ediciones Trea (pp. 55-65).

PNAS: "Climate change is projected to have severe impacts on the frequency and intensity of peak electricity demand" (pnas.org)

Revista Ingeniería y Competitividad (2024). Machine learning para sistemas energéticos en economías emergentes. Universidad del Valle.

Revista Ingeniería y Competitividad. (2023). Machine Learning en predicción de energía eléctrica: revisión sistemática.

Sánchez Durán, R. (2020). *El futuro y la demanda energética*. Universidad de Sevilla (España), (pp. 234).

SIEL (2020). Cobertura del servicio de energía eléctrica en Colombia. Sistema de Información Eléctrico Colombiano.

SIEL (2023). Integración de datos climáticos y energéticos. Sistema de Información Eléctrico Colombiano.

Spacewell. (2023). IA en gestión energética para optimizar suministros.

Tabares, J. & Velásquez, C. (2021). *Optimización del abastecimiento energético de Colombia mediante modelos bayesianos*. Repositorio UPB. <https://repository.upb.edu.co>

Torres Sánchez, A. S. (2023). *Predicción de la demanda de energía eléctrica usando modelos de IA*. Repositorio Universidad de Antioquia.

Unidad de Planeación Minero Energética. (s.f.). Proyecciones de demanda eléctrica en Colombia. UPME.

Unidad de Planeación Minero-Energética (UPME). (2022). Proyecciones de demanda energética 2022-2035. Ministerio de Minas y Energía. <https://www1.upme.gov.co>

Unidad de Planeación Minero-Energética (UPME). (2023). Lineamientos para modelos predictivos regionales. Unidad de Planeación Minero Energética.

Unidad de Planeación Minero-Energética (UPME). (2024, citado en Climate Tracker Latam). Los desafíos de las energías renovables frente al desabastecimiento y la demanda energética en Colombia.

UPME. (s.f.). Informe de Demanda de Energéticos.

https://www1.upme.gov.co/DemandayEficiencia/Documents/Informe_proyeccion_deman

UPME-Unidad de Planeación Minero-Energética (2010). Proyección de demanda de Energía en Colombia. (pp. 4-20)

UPME-Unidad de Planeación Minero-Energética (2023). Proyecciones por Unidad de Control de Pronóstico. (pp. 13-39)

XM. (2023). Informe anual del mercado eléctrico colombiano 2022. XM S.A. ESP.

<https://www.xm.com.co>

XM. (2024). En 2024, la demanda de energía en Colombia aumentó 2.3%.

https://www.xm.com.co/noticias/7504-en-2024-la-demanda-de-energia-en-colombia-aumento-23-en-comparacion-con-el-anoda_energeticos.pdf

XM. (2025). En 2024 la demanda de energía en Colombia aumentó 2.3% en comparación con el año anterior.

Xataka. (2023). DeepMind aplica ML en parques eólicos de EE.UU.