

Artificial Intelligence for the Optimization of Electrical Grids in Latin America

Inteligencia Artificial para la Optimización de Redes Eléctricas en Latinoamérica

Gustavo Javier Avila Gaibor

<https://orcid.org/0000-0003-0480-5669>

Independiente

Ecuador

Abstract.- This article explores the transformation of electricity grids in Latin America through the integration of artificial intelligence (AI). With energy demand expected to triple by 2050, AI is crucial for optimizing efficiency, reliability, and the integration of renewable energy. Countries such as Brazil, Mexico, and Chile are leading this adoption, using AI to manage distribution, balance supply and demand, and improve grid reliability. The study highlights that linear regression models predict energy efficiency with high accuracy ($R^2 = 0.86$), influenced by consumption, generation, and weather conditions. Optimization classification models achieve an accuracy close to 100%, while risk classification shows mixed results, with difficulties in minority classes, suggesting the need for data balancing. K-Means clustering identified three geographic segments of the grid with distinct operational and maintenance characteristics. ARIMA and LSTM models demonstrate a robust ability to predict energy demand and consumption, capturing complex temporal patterns. Linear optimization demonstrated effective balancing of energy distribution across diverse sources, and identified the potential for heuristic algorithms for future improvements. Despite challenges such as class imbalance in risk data, the need for more robust fault prediction models, and dynamic data integration, AI offers a promising path toward more efficient, resilient grids with greater customer satisfaction.

Keywords: Artificial intelligence, machine learning, models, optimization, networks.

Resumen.- El artículo explora la transformación de las redes eléctricas en América Latina mediante la integración de la inteligencia artificial (IA). Ante una demanda energética que se triplicará para 2050, la IA se vuelve crucial para optimizar la eficiencia, confiabilidad e integración de energías renovables. Países como Brasil, México y Chile lideran esta adopción, utilizando IA para gestionar la distribución, equilibrar la oferta y demanda, y mejorar la fiabilidad de la red. El estudio destaca que los modelos de regresión lineal predicen la eficiencia energética con alta precisión ($R^2 = 0.86$), influenciados por el consumo, generación y condiciones meteorológicas. Los modelos de clasificación de optimización alcanzan una precisión cercana al 100%, mientras que la clasificación de riesgo muestra resultados mixtos, con dificultades en clases minoritarias, sugiriendo la necesidad de balanceo de datos. El clustering K-Means identificó tres segmentos geográficos de la red con distintas características operativas y de mantenimiento. Los modelos ARIMA y LSTM demuestran una robusta capacidad para predecir la demanda y el consumo energético, capturando patrones temporales complejos. La optimización lineal demostró un balance efectivo en la distribución de energía entre diversas fuentes, y se identificó el potencial de algoritmos heurísticos para futuras mejoras. A pesar de los desafíos como el desequilibrio de clases en los datos de riesgo, la necesidad de modelos de predicción de fallas más robustos y la integración dinámica de datos, la IA ofrece un camino prometedor hacia redes más eficientes, resilientes y con mayor satisfacción del cliente.

Palabras clave: Inteligencia Artificial, Machine Learning, Modelos, Optimización, Redes.

1. Introducción

La integración de la inteligencia artificial (IA) en redes eléctricas inteligentes está transformando el panorama energético en América Latina, una región que enfrenta desafíos y oportunidades significativas en su búsqueda de soluciones energéticas sostenibles. A medida que los países anticipan un aumento triple de la demanda de energía para 2050, la optimización de las redes eléctricas a través de las tecnologías de IA se ha vuelto crucial para mejorar la eficiencia, la confiabilidad y la incorporación de fuentes de energía renovables [1].

Este desarrollo no solo aborda la necesidad urgente de modernización en la infraestructura energética, sino que también refleja un compromiso más amplio con la sostenibilidad ambiental y el crecimiento económico en el mundo [2].

Los países notables, como Brasil, México y Chile, están a la vanguardia de esta transformación, aprovechar la IA para mejorar el manejo de la red, optimizar la distribución de energía y mejorar la integración de fuentes renovables intermitentes como la energía solar y eólica [3]. Por ejemplo, la red nacional de Brasil utiliza cada vez más IA para administrar las salidas de energía variables, mientras que Chile está empleando algoritmos de IA para equilibrar la oferta y la demanda de manera efectiva, reducción de interrupciones y mejora de la fiabilidad de la red.

Sin embargo, la integración de la IA también presenta desafíos significativos, incluidos los obstáculos regulatorios, las preocupaciones de privacidad de los datos y la necesidad de medidas sólidas de ciberseguridad [4].

Los beneficios potenciales de utilizar la IA en las redes inteligentes son sustanciales, desde una mejor eficiencia operativa hasta un mejor mantenimiento predictivo y la optimización

económica dentro del sector energético. A medida que evolucionan las tecnologías de IA, facilitan los procesos de toma de decisiones basados en datos, ayudando a los servicios públicos a administrar mejor los recursos y responder a las fluctuaciones en la oferta y demanda de energía [5].

Sin embargo, la implementación exitosa de soluciones de IA requiere abordar consideraciones éticas y barreras sistémicas que puedan obstaculizar el progreso, asegurando que la transición a los sistemas de energía impulsados por la IA sea equitativo y sostenible para todas las partes interesadas involucradas [6].

Los esfuerzos continuos para aprovechar la IA para la optimización de las redes eléctricas inteligentes en América Latina subrayan el compromiso de la región con un futuro de energía sostenible [7]. Fomentando la innovación, mejorar la gestión de la energía y abordar los desafíos existentes, los países latinoamericanos se están posicionando no solo para satisfacer las crecientes demandas de energía, sino también para convertirse en líderes en la transición global a fuentes de energía renovable y sistemas de energía inteligente.

La evolución de las redes eléctricas ha sufrido una transformación significativa de los sistemas centralizados a las "redes inteligentes" avanzadas de hoy, en gran medida impulsadas por avances tecnológicos y la necesidad de eficiencia y sostenibilidad [8]. Inicialmente diseñado para una entrega simple de energía, las redes tradicionales enfrentaron limitaciones en confiabilidad y escalabilidad.

Esto provocó un cambio hacia redes descentralizadas, donde la inteligencia artificial (IA) ha desempeñado un papel fundamental en la mejora de la eficiencia operativa, la seguridad y la resistencia a través del análisis de datos en tiempo real y los sistemas automatizados [9].

Edge Computing, un concepto que surgió a fines de la década de 1990 y ganó prominencia a mediados de los 2010, ha sido fundamental para minimizar la latencia y el uso de ancho de banda procesando datos más cercanos a su fuente [10].

Este enfoque tecnológico es particularmente relevante en el contexto del creciente Internet de las cosas (IoT) y la creciente demanda de procesamiento de datos en tiempo real en los sistemas de energía modernos. En América Latina y el Caribe, el sector energético está actualmente experimentando una transformación significativa, con un enfoque en la integración de fuentes de energía renovables junto con las tradicionales [11]. A medida que los países de la región anticipan un triple aumento de la demanda de energía para 2050, la necesidad urgente de acelerar la adopción de las energías renovables mientras equilibra el crecimiento económico es crítico.

Brasil ejemplifica esta transición, ya que la energía renovable ha comenzado a potenciar más del 50% de su consumo nacional, mostrando el potencial de prácticas sostenibles en la región. La modernización de las redes eléctricas es esencial para acomodar la afluencia de energía renovable. Sin embargo, los desafíos como la infraestructura de transmisión inadecuada persisten, lo que puede conducir a cuellos de botella de energía y problemas de precios en varios mercados de electricidad nodal [12].

Para abordar estos desafíos, las redes inteligentes, caracterizadas por la automatización inteligente y la gestión de energía predictiva, se están adoptando para mejorar la estabilidad de la red y optimizar la distribución de energía, asegurando que la red eléctrica pueda satisfacer las demandas modernas sin comprometer la confiabilidad [13].

Las tecnologías de IA y el aprendizaje automático son fundamentales para esta

evolución, habilitar el monitoreo mejorado, el mantenimiento predictivo y la integración eficiente de fuentes renovables, que en última instancia conduce a una red eléctrica más adaptable y eficiente [14].

Los esfuerzos continuos para utilizar estas tecnologías reflejan un compromiso de fomentar un futuro de energía sostenible en América Latina, equilibrar la diversa matriz energética de la región y promover la innovación tecnológica [15].

Políticas gubernamentales que apoyan la integración de IA

La integración exitosa de la inteligencia artificial (IA) en las redes eléctricas inteligentes requiere políticas gubernamentales sólidas que faciliten la innovación al tiempo que aborda los posibles desafíos. Estas políticas deben estar alineadas con el paisaje en rápida evolución de las tecnologías energéticas y la creciente demanda de prácticas sostenibles en el sector energético [16]. Un marco regulatorio integral es esencial para establecer estándares que promuevan la interoperabilidad, la seguridad y el uso ético de la IA en los sistemas de energía .

Mejoras regulatorias

Se insta a los gobiernos a revisar los marcos regulatorios existentes para acomodar mejor las aplicaciones de IA en redes inteligentes. Esto incluye actualizar las políticas para garantizar que los sistemas de IA puedan comunicarse de manera efectiva con la infraestructura de la red tradicional [17].

Un grupo de trabajo dedicado puede optimizar la implementación y la aplicación de estas políticas, coordinando los esfuerzos entre varios organismos regulatorios, como los ministerios de energía y las comisiones reguladoras. Además, las aprobaciones regulatorias para los

servicios impulsados por la IA deben ser aceleradas para fomentar la innovación oportuna en los mercados de energía digital [18].

Promoción de asociaciones público-privadas

Las asociaciones público-privadas (PPP) son críticas para impulsar la innovación dentro del sector energético. Al colaborar con entidades del sector privado, los gobiernos pueden aprovechar la experiencia de los desarrolladores de tecnología de IA al tiempo que garantizan el cumplimiento de los estándares legales]. Las políticas deben incentivar la investigación y el desarrollo en soluciones energéticas impulsadas por la IA, promoviendo así un ecosistema propicio para la integración de fuentes de energía renovables en la red.

Estas colaboraciones son vitales para abordar las complejidades asociadas con las implementaciones de IA a gran escala en la infraestructura energética, particularmente en relación con la privacidad de los datos y la ciberseguridad [19].

Ciberseguridad y estándares éticos

A medida que el uso de IA se expande dentro del sector energético, la implementación de los estándares de ciberseguridad se vuelve imprescindible para proteger la infraestructura crítica. Los gobiernos deben adoptar estándares internacionales y exigir evaluaciones regulares de vulnerabilidad para compañías energéticas [20].

Además, los desafíos éticos asociados con la IA, como el sesgo y la transparencia en los procesos de toma de decisiones, deben abordarse a través de marcos de gobernanza que garanticen la equidad y la responsabilidad en las aplicaciones de IA [21].

Apoyo a los objetivos de desarrollo sostenible

La integración de la IA en las redes inteligentes está estrechamente vinculada al logro de Objetivos de Desarrollo Sostenible (ODS), particularmente en el contexto de la acción climática y el consumo responsable. Las políticas que fomentan el uso de IA para optimizar el consumo de energía y minimizar los desechos pueden reducir significativamente las emisiones de carbono y reforzar los esfuerzos para combatir el cambio climático [22].

Alineando iniciativas de IA con objetivos de sostenibilidad, los gobiernos pueden crear un sistema de energía más resistente y eficiente que beneficie a los consumidores y al medio ambiente [23].

Tecnologías de inteligencia artificial

La aplicación de tecnologías de inteligencia artificial (IA) en redes eléctricas inteligentes está transformando los sistemas de energía, particularmente en América Latina [24], donde existe una creciente necesidad de soluciones eficientes de gestión de energía. Esta sección describe las técnicas clave de IA empleadas para optimizar las operaciones en redes inteligentes, destacando sus roles en la mejora de la eficiencia energética y el apoyo a la integración de energía renovable.

Aprendizaje automático en cuadrículas inteligentes

El aprendizaje automático (ML) ha surgido como un componente fundamental en la optimización de las redes inteligentes, que ofrece metodologías robustas para analizar conjuntos de datos extensos y automatizar procesos de toma de decisiones. Técnicas de ML como el aprendizaje supervisado, incluidas la regresión lineal y las máquinas de vectores de soporte, se aplican comúnmente para el pronóstico de carga y la gestión de la respuesta a la demanda [25].

Estos modelos permiten a los servicios públicos predecir patrones de consumo de energía, que es esencial para equilibrar la oferta y la demanda en tiempo real. Además, ML facilita el desarrollo de estrategias que mejoran la eficiencia energética al optimizar la calefacción, ventilación y sistemas de aire acondicionado en edificios inteligentes, así como programación de procesos industriales para minimizar los desechos [26].

En particular, las implementaciones del mundo real de ML en distribución y almacenamiento de energía han demostrado mejoras significativas en la eficiencia operativa y la experiencia del cliente [27].

Análisis de datos y análisis predictivo

La integración de las tecnologías de IA en las redes eléctricas inteligentes requiere capacidades sofisticadas de análisis de datos. Los algoritmos de IA pueden procesar grandes volúmenes de datos de diversas fuentes de energía, lo que permite a los servicios públicos emplear análisis predictivos para anticipar escenarios operativos. Al utilizar diversas formas de análisis, los operadores de la Grid de Analítica, descriptivo, diagnóstico, predictivo y prescriptivo, pueden mejorar sus procesos de toma de decisiones y abordar preventivamente problemas potenciales [28].

Sin embargo, los desafíos relacionados con la calidad de los datos persisten, ya que muchos modelos a menudo están capacitados en conjuntos de datos sintéticos debido al acceso limitado a datos operativos reales. Los esfuerzos para mejorar los métodos de recopilación de datos y desarrollar conjuntos de datos multimodales de alta calidad son críticos para mejorar la precisión y efectividad de las aplicaciones de IA en los sistemas de energía [29].

Optimización de sistemas de energía renovable

Las tecnologías de IA juegan un papel crucial en la optimización de los sistemas de energía renovable (RES), que son vitales para la transición hacia soluciones de energía sostenibles. Las técnicas de ML se aplican en varias aplicaciones RE, incluidas las solares, el viento y los sistemas de residuos de energía, para predecir el rendimiento y mejorar los parámetros operativo. Por ejemplo, se han utilizado modelos de aprendizaje automático para mejorar la eficiencia de los sistemas municipales de residuos sólidos a la energía, lo que demuestra la versatilidad de la tecnología en abordar los desafíos ambientales al tiempo que optimiza la producción de energía [30].

Aplicaciones de IA en redes inteligentes

Las tecnologías de IA juegan un papel fundamental en la mejora de la eficiencia, confiabilidad y sostenibilidad de las redes inteligentes en diversas aplicaciones. Estas aplicaciones abordan desafíos críticos asociados con la gestión de la energía y la integración de fuentes de energía renovables [31].

Optimización de la distribución de energía

Las redes inteligentes impulsadas por IA optimizan la distribución de energía, lo que ayuda a reducir las pérdidas de energía y prevenir interrupciones. Mediante el uso de medidores inteligentes y sistemas de respuesta a la demanda, la IA analiza los patrones de consumo para facilitar el equilibrio de carga en tiempo real, asegurando un flujo de energía eficiente en toda la red [32].

Esta optimización es particularmente crucial a medida que más consumidores adoptan recursos energéticos distribuidos, tales como paneles solares en la azotea y sistemas de almacenamiento de baterías [33].

Gestión de interrupciones mejoradas

Una de las aplicaciones significativas de la IA en las redes inteligentes es la mejora de los sistemas de gestión de interrupciones. AI mejora las alertas de interrupción a través de sofisticadas redes de sensores que proporcionan datos en tiempo real,

permitiendo que los servicios públicos predecan y respondan a las interrupciones de manera más efectiva. Por ejemplo, la IA puede identificar posibles interrupciones antes de que ocurran, proporcionando a los operadores alertas que diferencian entre interrupciones individuales, callejeras y zonales. Esta capacidad permite una restauración más rápida de los servicios y una mejor confiabilidad [34].

Pronóstico de carga avanzada

El pronóstico de carga preciso es esencial para una gestión efectiva de la red, especialmente con la variabilidad introducida por las fuentes de energía renovable. AI permite a los servicios públicos utilizar modelos de análisis predictivos que combinan datos de infraestructura de medición avanzada (AMI) para generar pronósticos más confiables de cargas de energía y generación de energía renovable [35]. Este nivel de precisión es crítico para gestionar las fluctuaciones en la demanda y la oferta, que a menudo están representados por el fenómeno de la "curva de pato".

Integración de fuentes de energía renovable

A medida que las fuentes de energía renovables como el viento y la energía solar se vuelven más frecuentes, la IA ayuda a su integración perfecta a la red eléctrica. Las tecnologías de IA ayudan a administrar la naturaleza intermitente de estas fuentes de energía al optimizar la generación y el almacenamiento, habilitando el cambio de carga efectivo y el equilibrio de la producción de energía con el consumo [36].

La incorporación de dispositivos de almacenamiento de energía, respaldados por AI, mejora aún más la resiliencia de la red al permitir el almacenamiento de energía excedente durante los tiempos de producción máximos [37].

Ciberseguridad y resiliencia

La IA también juega un papel vital en la mejora de la ciberseguridad de las redes inteligentes. Con la creciente digitalización de los sistemas de energía, las soluciones impulsadas por IA pueden identificar y responder a posibles amenazas ciberneticas, asegurando la integridad y la seguridad de las operaciones de la red [38]. Medidas de seguridad robustas, los canales de comunicación cifrados y los mecanismos de defensa avanzados son esenciales para proteger la red de las vulnerabilidades.

Integración de vehículos eléctricos

La creciente adopción de vehículos eléctricos (EV) presenta desafíos y oportunidades para redes inteligentes. AI facilita la gestión de la carga dinámica al habilitar, coordinación del tiempo de la carga y descarga de EV, lo que ayuda a reducir el estrés de carga máxima y mejorar la eficiencia energética [39].

La tecnología de vehículo a red (V2G), alimentada por IA, permite a los EV devolver la energía almacenada a la red durante la demanda máxima, optimizar el uso general de energía e integrar los recursos renovables de manera más efectiva [40].

Considerando las experiencias positivas de la inteligencia artificial en el manejo energético, el objetivo de esta investigación es demostrar su importancia para la Optimización de Redes Eléctricas en Latinoamérica y conducir a un manejo sostenible de los recursos naturales.

2. Materiales y Métodos

2.1 Modelos Estadísticos

Regresión Lineal Múltiple

Se implementó un modelo de regresión lineal múltiple para predecir la eficiencia energética de la red eléctrica. Las variables predictoras incluyen: Consumo de energía (kWh), generación de energía (kWh), condiciones meteorológicas (temperatura, humedad, velocidad del viento, radiación solar) y características del equipo (edad, puntaje de mantenimiento, estado del transformador, condición del cable).

Regresión Logística

Se aplicó regresión logística para dos propósitos: clasificación de riesgo de falla en la red y clasificación de potencial de optimización.

ARIMA (Autoregressive Integrated Moving Average) Se implementó un modelo ARIMA para predecir la demanda de energía y la generación de energía. El modelo identificó patrones temporales significativos en los datos, con coeficientes estadísticamente significativos para los términos AR (Lag 1-5).

Redes Neuronales Recurrentes (RNN) con LSTM

Se desarrolló un modelo LSTM para predecir el consumo de energía, utilizando secuencias temporales de datos. El modelo mostró un rendimiento sólido con un RMSE de 51.5277 kWh, demostrando su capacidad para capturar patrones complejos en los datos de consumo.

Clustering con K-Means

Se aplicó K-Means para agrupar subestaciones y puntos de distribución según su rendimiento y características geográficas. Los resultados mostraron tres clusters distintos con características significativas: cluster 0: Latitud media (-17.43), tiempo de respuesta 13.83

minutos, cluster 1: Latitud positiva (4.90), tiempo de respuesta 13.60 minutos, cluster 2: Latitud negativa (-20.67), tiempo de respuesta 14.23 minutos.

Optimización

Se implementaron dos enfoques de optimización: programación Lineal: Para optimizar la distribución de energía entre diferentes fuentes (solar, eólica, térmica) y optimización Heurística: Se discutieron los conceptos de Algoritmos Genéticos y Optimización por Enjambre de Partículas como enfoques potenciales para problemas de optimización complejos.

2.2 Datos utilizados

El conjunto de datos simulado contuvo información detallada sobre el funcionamiento de una red eléctrica inteligente en Latinoamérica, generada para un período de 5 años (2020-2025) con una frecuencia horaria. El dataset consta de 5000 registros y 20 variables.

Variables Principales

Variables de Consumo y Generación: `energy_consumption_kWh`: Consumo de energía en kilovatios-hora, `energy_generation_kWh`: Generación de energía total en kilovatios-hora, `energy_demand_kWh`: Demanda de energía en kilovatios-hora, `energy_efficiency`: Eficiencia energética del sistema y `'energy_losses_percent'`: Porcentaje de pérdidas energéticas.

Variables Meteorológicas: `temperature_C`: Temperatura ambiente en grados Celsius, `humidity_percent`: Porcentaje de humedad relativa, `'wind_speed_mps'`: Velocidad del viento en metros por segundo y `'solar_radiation_Wm2'`: Radiación solar en vatios por metro cuadrado.

Variables de Estado del Sistema: `equipment_age_years`: Edad de los equipos en años, `maintenance_score`: Puntaje de mantenimiento (0-1), `transformer_status`: Estado del transformador (0: Normal, 1: Advertencia, 2: Falla) y `cable_condition`: Condición del cable (0: Bueno, 1: Desgastado).

Variables Geográficas: `latitude`: Latitud geográfica, `longitude`: Longitud geográfica y `altitude_m`: Altitud en metros.

Variables de Operación: `response_time_minutes`: Tiempo de respuesta a incidentes en minutos, `operational_cost_USD`: Costo operativo en dólares y `customer_satisfaction`: Índice de satisfacción del cliente (0-1).

Características del Conjunto de Datos

Distribución Temporal: Periodo: 5 años (2020-2025), frecuencia: Horaria con un total de registros: 5000.

Patrones y Variaciones: patrones diarios: Mayor consumo en horas pico (tarde/noche), patrones estacionales: Variaciones en el consumo y generación según la estación, variaciones geográficas: Diferentes condiciones climáticas y topográficas y variaciones operativas: Diferentes estados de mantenimiento y edad de equipos.

Calidad de los Datos

Consistencia: No valores nulos, valores físicamente plausibles y coherencia entre variables relacionadas.

Rangos de Valores: temperatura: 18°C - 35°C, humedad: 60% - 95%, velocidad del viento: 0 - 15 m/s, radiación solar: 0 - 350 W/m², edad de equipos: 1 - 30 años, puntaje de mantenimiento: 0 - 1, eficiencia energética: 0 - 1 y satisfacción del cliente: 0 - 1.

Relaciones entre Variables: la eficiencia energética estuvo influenciada por el consumo y la generación, el tiempo de respuesta estuvo relacionado con la edad del equipo y el mantenimiento, la satisfacción del cliente dependió de las pérdidas, el tiempo de respuesta y el estado del sistema y la generación de energía considera fuentes renovables (solar y eólica) y no renovables (térmica).

Consideraciones Metodológicas

Los datos fueron generados siguiendo patrones observados en redes eléctricas latinoamericanas, incluyendo: patrones de consumo típicos, variaciones climáticas regionales, características operativas de la red y factores geográficos relevantes.

Estos datos proporcionaron una representación realista del funcionamiento de una red eléctrica inteligente en Latinoamérica, permitiendo el análisis y optimización de diferentes aspectos del sistema.

3. Resultados

Análisis de Eficiencia Energética

Modelo de Regresión Lineal

El modelo de regresión lineal para predecir la eficiencia energética mostró resultados altamente significativos con RMSE: 0.0347 y R²: 0.86.

Estos valores indican que el modelo explica el 86% de la variabilidad en la eficiencia energética y tiene un error de predicción relativamente bajo. Las variables más influyentes incluyen: consumo y generación de energía, condiciones meteorológicas y estado del equipo y mantenimiento.

Análisis de Clasificación

Clasificación de Riesgo

Los modelos de clasificación para identificar riesgos en la red mostraron resultados mixtos: Random Forest: Precisión de 85.87% y Gradient Boosting: Precisión de 85.13% (Figura 1).

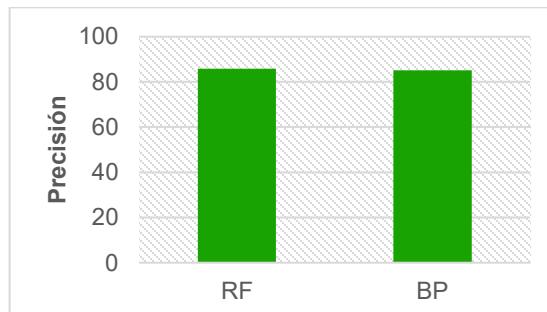


Fig 1. Clasificación de riesgos de modelos usados.

Los modelos identificaron correctamente la mayoría de los casos de riesgo bajo (clase 0), pero tuvieron dificultades con las clases minoritarias (clase 2). Esto sugiere la necesidad de: balancear mejor el conjunto de datos, implementar técnicas para manejar clases desbalanceadas y considerar métricas adicionales como el F1-score para evaluar el rendimiento en clases minoritarias.

Clasificación de Potencial de Optimización

Los modelos para identificar oportunidades de optimización mostraron un rendimiento excelente: Random Forest: Precisión de 99.87% y Gradient Boosting: Precisión de 100% (Figura 2).

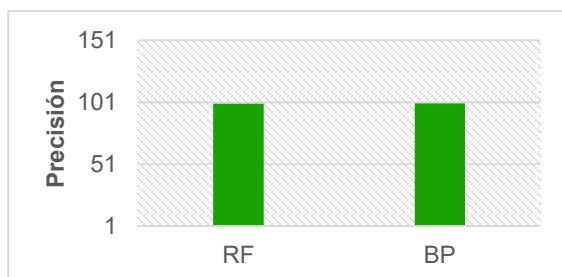


Fig 2. Clasificación de potencial de optimización de modelos usados.

Estos resultados indican que el sistema puede identificar con alta precisión las áreas que requieren optimización, lo que es crucial para la gestión preventiva de la red.

Análisis de Clustering

Segmentación de la Red

El análisis de clustering K-Means identificó tres clusters principales con características distintas (Figura 3).



Fig 3. Tiempo de respuesta de Clúster.

Cluster 1 (Latitud -17.43) con tiempo de respuesta: 13.83 minutos, posición geográfica: Centro-sur y cena respuesta y mantenimiento.

Cluster 2 (Latitud 4.90): tiempo de respuesta: 13.60 minutos, posición geográfica: Norte, excelente respuesta y mantenimiento.

Cluster 3 (Latitud -20.67): tiempo de respuesta: 14.23 minutos, posición geográfica: Sur y mayor tiempo de respuesta, potencial de mejora.

Análisis de Series Temporales

Predicción de Demanda

El modelo ARIMA identificó patrones temporales significativos: coeficientes AR

significativos para lags 1-5. buena capacidad de predicción de la demanda energética e identificación de estacionalidad y tendencias temporales.

Modelo LSTM

El modelo LSTM para predicción de consumo mostró: RMSE: 51.5277 kWh, capacidad para capturar patrones complejos en el consumo y Utilización efectiva de secuencias temporales.

Análisis de Optimización

Distribución de Energía

La optimización lineal para la distribución de energía mostró: generación óptima: 110.86 kWh, balance efectivo entre fuentes (solar, eólica, térmica) y cumplimiento de la demanda energética.

Potencial de Optimización Heurística, se identificaron oportunidades para implementar: algoritmos genéticos para planificación de expansión, optimización por Enjambre de Partículas para ajustes dinámicos.

Las fortalezas del sistema fueron predicción Robusta por altos niveles de precisión en la predicción de eficiencia y demanda, clasificación Efectiva: Excelente identificación de oportunidades de optimización, segmentación Clara: clusters geográficos bien definidos con características distintivas y balance adecuado en la distribución de energía.

A pesar los buenos resultados se requieren áreas de mejora como mejorar la detección de riesgos minoritarios, implementar modelos más robustos para predicción de fallas, desarrollar modelos más avanzados para ajustes en tiempo real e incorporar más fuentes de datos externas.

Por lo que se recomienda implementar el sistema de clasificación de optimización para

mantenimiento preventivo, desarrollar estrategias específicas para cada clúster geográfico, mejorar la monitorización de las áreas con mayor tiempo de respuesta, mantener la actualización continua de los modelos predictivos, mejora de la eficiencia, reducción de pérdidas energéticas, optimización del mantenimiento preventivo, mejor distribución de recursos.

Así mismo se debe mejoras de la resiliencia, mediante identificación temprana de riesgos, mejor respuesta a incidentes, optimización de recursos en áreas críticas, mejora de la satisfacción del cliente, reducción de tiempos de respuesta, mejor gestión de la demanda y optimización del servicio.

4. Discusión

Los resultados de la investigación revelan un panorama prometedor para la integración de la inteligencia artificial (IA) en la gestión de redes energéticas, destacando su potencial para mejorar significativamente la eficiencia, la resiliencia y la satisfacción del cliente. Estos hallazgos se alinean con la creciente literatura que subraya el papel transformador de la IA en los sistemas energéticos [41].

En el análisis de eficiencia energética, el modelo de regresión lineal demostró una capacidad robusta para predecir la eficiencia, explicando el 86% de su variabilidad con un error de predicción bajo (RMSE: 0.0347). Variables como el consumo y la generación de energía, las condiciones meteorológicas y el estado del equipo fueron identificadas como las más influyentes. Esto concuerda con la visión de las redes inteligentes impulsadas por IA, que pueden optimizar la gestión energética en diversos sectores, incluyendo la manufactura [42].

Los modelos de clasificación de riesgo exhibieron una precisión del 85.87% para Random Forest y del 85.13% para Gradient Boosting. Si bien estos modelos fueron efectivos en la identificación de riesgos de clase mayoritaria (riesgo bajo, clase 0), mostraron limitaciones con las clases minoritarias (clase 2). Esta dificultad resalta la necesidad de abordar el desequilibrio de clases en los conjuntos de datos y considerar métricas adicionales como el F1-score para una evaluación más completa del rendimiento, un desafío recurrente en la aplicación de machine learning a sistemas energéticos [43].

Por otro lado, los modelos de clasificación para el potencial de optimización demostraron un rendimiento excepcional, alcanzando precisiones del 99.87% (Random Forest) y 100% (Gradient Boosting). Estos resultados son cruciales para la gestión preventiva de la red, permitiendo la identificación de áreas que requieren optimización con una alta fiabilidad [44], [45].

El análisis de clustering K-Means reveló una segmentación clara de la red en tres grupos geográficos distintos: un clúster centro-sur (Latitud -17.43) con un tiempo de respuesta de 13.83 minutos y buena respuesta y mantenimiento; un clúster norte (Latitud 4.90) con un tiempo de respuesta de 13.60 minutos y excelente respuesta y mantenimiento; y un clúster sur (Latitud -20.67) con el mayor tiempo de respuesta de 14.23 minutos y potencial de mejora. Esta segmentación es fundamental para el desarrollo de estrategias de mantenimiento preventivo y optimización adaptadas a las características específicas de cada región [46].

En cuanto al análisis de series temporales, el modelo ARIMA demostró una buena capacidad para predecir la demanda energética, identificando patrones de estacionalidad y tendencias temporales significativas. El modelo LSTM, por su parte, mostró una capacidad superior para capturar patrones complejos en el

consumo con un RMSE de 51.5277 kWh, lo que refuerza su utilidad para la predicción de consumo energético [47].

Finalmente, el análisis de optimización lineal para la distribución de energía indicó una generación óptima de 110.86 kWh, logrando un balance efectivo entre diversas fuentes (solar, eólica, térmica) y el cumplimiento de la demanda energética. Se identificaron también oportunidades para la implementación de algoritmos heurísticos como los algoritmos genéticos y la optimización por enjambre de partículas para la planificación de expansión y ajustes dinámicos, respectivamente. Esto es consistente con las tendencias actuales que exploran la IA para la optimización de la red eléctrica [48].

5. Conclusiones

Los resultados obtenidos demuestran de manera contundente el gran potencial de la inteligencia artificial (IA) para revolucionar la gestión de redes energéticas, permitiendo una operación más eficiente, resiliente y orientada al cliente. La precisión y robustez de los modelos predictivos para la eficiencia energética y la demanda, junto con la excelente capacidad de clasificación para identificar oportunidades de optimización, son fortalezas innegables del sistema. Además, la segmentación geográfica de la red a través del análisis de clustering K-Means ofrece una base sólida para estrategias de gestión diferenciadas.

Si bien se observa una necesidad clara de mejorar la detección de riesgos minoritarios y de desarrollar modelos más avanzados para la predicción de fallas y la optimización dinámica en tiempo real, estos desafíos no opacan los logros significativos. Las oportunidades de optimización identificadas, la capacidad de balancear eficazmente las fuentes de energía y la mejora en los tiempos de respuesta son indicativos de un sistema con la capacidad de transformar positivamente la operación de la red.

En definitiva, la implementación de este sistema basado en IA representa un paso fundamental hacia la creación de redes inteligentes (smart grids) verdaderamente adaptativas y proactivas, capaces de anticipar y responder eficientemente a las complejidades del panorama energético actual y futuro. La inversión en las áreas de mejora identificadas, junto con la adopción de las recomendaciones de implementación, será crucial para maximizar el impacto de esta tecnología innovadora en la eficiencia, la resiliencia y la satisfacción del cliente.

Referencias:

- [1] Mukhamediev, R. I., Popova, Y., Kuchin, Y., Zaitseva, E., Kalimoldayev, A., Symagulov, A., ... & Yelis, M. (2022). Review of artificial intelligence and machine learning technologies: Classification, restrictions, opportunities and challenges. *Mathematics*, 10(15), 2552. <https://doi.org/10.3390/math10152552>
- [2] Suman, A. (2021). Role of renewable energy technologies in climate change adaptation and mitigation: A brief review from Nepal. *Renewable and Sustainable Energy Reviews*, 151, 111524. <https://doi.org/10.1016/j.rser.2021.111524>
- [3] Beltrán Gallego, J. D., Quintero Ríos, M., López García, D., & Carvajal Quintero, S. X. (2022). Energy Management Systems in Latin American Industry: Case Study Colombia. *TecnoLógicas*, 25(54). <http://dx.doi.org/10.22430/22565337.2379>
- [4] Greenstein, S. (2022). Preserving the rule of law in the era of artificial intelligence (AI). *Artificial Intelligence and Law*, 30(3), 291-323. <https://link.springer.com/article/10.1007/s10506-021-09294-4>
- [5] Entezari, A., Aslani, A., Zahedi, R., & Noorollahi, Y. (2023). Artificial intelligence and machine learning in energy systems: A bibliographic perspective. *Energy Strategy Reviews*, 45, 101017. <https://doi.org/10.1016/j.esr.2022.101017>
- [6] Naik, N., Hameed, B. M., Shetty, D. K., Swain, D., Shah, M., Paul, R., ... & Soman, B. K. (2022). Legal and ethical consideration in artificial intelligence in healthcare: who takes responsibility?. *Frontiers in surgery*, 9, 862322. <http://dx.doi.org/10.3389/fsurg.2022.862322>
- [7] Gallegos, J., Arévalo, P., Montaleza, C., & Jurado, F. (2024). Sustainable electrification—advances and challenges in electrical-distribution networks: a review. *Sustainability*, 16(2), 698. <https://doi.org/10.3390/su16020698>
- [8] Mbungu, N. T., Ismail, A. A., AlShabi, M., Bansal, R. C., Elnady, A., & Hamid, A. K. (2023). Control and estimation techniques applied to smart microgrids: A review. *Renewable and Sustainable Energy Reviews*, 179, 113251. <https://doi.org/10.1016/j.rser.2023.113251>
- [9] Liu, Z., Gao, Y., & Liu, B. (2022). An artificial intelligence-based electric multiple units using a smart power grid system. *Energy Reports*, 8, 13376-13388. <https://doi.org/10.1016/j.egyr.2022.09.138>
- [10] Kong, L., Tan, J., Huang, J., Chen, G., Wang, S., Jin, X., ... & Das, S. K. (2022). Edge-computing-driven internet of things: A survey. *ACM Computing Surveys*, 55(8), 1-41. <http://dx.doi.org/10.1109/JIOT.2022.3200431>
- [11] Lu, S., Lu, J., An, K., Wang, X., & He, Q. (2023). Edge computing on IoT for machine signal processing and fault diagnosis: A

- review. IEEE Internet of Things Journal, 10(13), 11093-11116. <https://ieeexplore.ieee.org/document/10026418>
- [12] Gehrke, P., Goretti, A. A. T., & Avila, L. V. (2021). Impactos da matriz energética no desenvolvimento sustentável do Brasil. Revista de Administração da UFSM, 14, 1032-1049. <http://dx.doi.org/10.5902/1983465964409>
- [13] Bhattacharai, T. N., Ghimire, S., Mainali, B., Gorjani, S., Treichel, H., & Paudel, S. R. (2023). Applications of smart grid technology in Nepal: status, challenges, and opportunities. Environmental Science and Pollution Research, 30(10), 25452-25476. <https://doi.org/10.1007/s11356-022-19084-3>
- [14] Mazhar, T., Irfan, H. M., Haq, I., Ullah, I., Ashraf, M., Shloul, T. A., ... & Elkamchouchi, D. H. (2023). Analysis of challenges and solutions of IoT in smart grids using AI and machine learning techniques: A review. Electronics, 12(1), 242. <https://doi.org/10.3390/electronics12010242>
- [15] Icaza-Alvarez, D., Jurado, F., & Tostado-Véliz, M. (2024). Smart energy planning for the decarbonization of Latin America and the Caribbean in 2050. Energy Reports, 11, 6160-6185. <https://doi.org/10.1016/j.egyr.2024.05.067>
- [16] Lage, M., & Castro, R. (2022). A practical review of the public policies used to promote the implementation of pv technology in smart grids: the case of portugal. Energies, 15(10), 3567. <http://dx.doi.org/10.3390/en15103567>
- [17] Guo, C., Luo, F., Cai, Z., & Dong, Z. Y. (2021). Integrated energy systems of data centers and smart grids: State-of-the-art and future opportunities. Applied Energy, 301, 117474. <https://doi.org/10.1016/j.apenergy.2021.117474>
- [18] Niet, I. A., Dekker, R., & van Est, R. (2022). Seeking public values of digital energy platforms. Science, Technology, & Human Values, 47(3), 380-403. <http://dx.doi.org/10.1177/01622439211054430>
- [19] Li, Y., & Yan, J. (2022). Cybersecurity of smart inverters in the smart grid: A survey. IEEE Transactions on Power Electronics, 38(2), 2364-2383. <https://ieeexplore.ieee.org/document/9889215>
- [20] Mohammadi, F. (2021). Emerging challenges in smart grid cybersecurity enhancement: A review. Energies, 14(5), 1380. <https://doi.org/10.3390/en14051380>
- [21] Kumar, P., Chauhan, S., & Awasthi, L. K. (2023). Artificial intelligence in healthcare: review, ethics, trust challenges & future research directions. Engineering Applications of Artificial Intelligence, 120, 105894. <https://doi.org/10.1016/j.engappai.2023.105894>
- [22] Pimenow, S., Pimenowa, O., & Prus, P. (2024). Challenges of artificial intelligence development in the context of energy consumption and impact on climate change. Energies, 17(23), 5965. <https://doi.org/10.3390/en17235965>
- [23] Zhang, Y., Teoh, B. K., Wu, M., Chen, J., & Zhang, L. (2023). Data-driven estimation of building energy consumption and GHG emissions using explainable artificial intelligence. Energy, 262, 1. <https://doi.org/10.1016/j.energy.2022.125468>

- [24] Fernández-Miranda, M., Román-Acosta, D., Jurado-Rosas, A. A., Limón-Dominguez, D., & Torres-Fernández, C. (2024). Artificial intelligence in Latin American universities: Emerging challenges. *Computación y Sistemas*, 28(2), 435-450. <https://doi.org/10.13053/cys-28-2-4822>
- [25] Sahani, N., Zhu, R., Cho, J. H., & Liu, C. C. (2023). Machine learning-based intrusion detection for smart grid computing: A survey. *ACM Transactions on Cyber-Physical Systems*, 7(2), 1-31. <http://dx.doi.org/10.1145/3578366>
- [26] Bashir, A. K., Khan, S., Prabadevi, B., Deepa, N., Alnumay, W. S., Gadekallu, T. R., & Maddikunta, P. K. R. (2021). Comparative analysis of machine learning algorithms for prediction of smart grid stability. *International Transactions on Electrical Energy Systems*, 31(9), e12706. <http://dx.doi.org/10.1002/2050-7038.12706>
- [27] Mostafa, N., Ramadan, H. S. M., & Elfarouk, O. (2022). Renewable energy management in smart grids by using big data analytics and machine learning. *Machine Learning with Applications*, 9, 100363. <https://doi.org/10.1016/j.mlwa.2022.100363>
- [28] Yan, Z., & Wen, H. (2021). Performance analysis of electricity theft detection for the smart grid: An overview. *IEEE Transactions on Instrumentation and Measurement*, 71, 1-28. <http://dx.doi.org/10.1109/TIM.2021.3127649>
- [29] Geng, Y., Zhang, N., & Zhu, R. (2023). Research progress analysis of sustainable smart grid based on CiteSpace. *Energy Strategy Reviews*, 48, 101111. <https://doi.org/10.1016/j.esr.2023.101111>
- [30] Xia, W., Jiang, Y., Chen, X., & Zhao, R. (2022). Application of machine learning algorithms in municipal solid waste management: A mini review. *Waste Management & Research*, 40(6), 609-624. <http://dx.doi.org/10.1177/0734242X211033716>
- [31] Khalid, M. (2024). Smart grids and renewable energy systems: Perspectives and grid integration challenges. *Energy Strategy Reviews*, 51, 101299. <https://doi.org/10.1016/j.esr.2024.101299>
- [32] Omitaomu, O. A., & Niu, H. (2021). Artificial intelligence techniques in smart grid: A survey. *Smart Cities*, 4(2), 548-568. <https://doi.org/10.3390/smartcities4020029>
- [33] Lamnatou, C., Chemisana, D., & Cristofari, C. (2022). Smart grids and smart technologies in relation to photovoltaics, storage systems, buildings and the environment. *Renewable Energy*, 185, 1376-1391. <https://doi.org/10.1016/j.renene.2021.11.019>
- [34] Berdugo-Sarmiento, K., Silva-Ortega, J., & Eras, J. J. C. (2024). Electricity Public Service Quality Management in Colombia. In 2024 9th International Engineering, Sciences and Technology Conference (IESTEC) (pp. 587-592). IEEE. <http://dx.doi.org/10.1109/IESTEC62784.2024.10820198>
- [35] Mohiddin, M. K., Kohli, R., Dutt, V. S. I., Dixit, P., & Michal, G. (2021). Energy-Efficient Enhancement for the Prediction-Based Scheduling Algorithm for the Improvement of Network Lifetime in WSNs. *Wireless Communications and Mobile Computing*, 2021(1), 9601078. <http://dx.doi.org/10.1155/2021/9601078>
- [36] Aghsaei, R., Hecht, C., Schwinger, F., Figgener, J., Jarke, M., & Sauer, D. U. (2023). <https://doi.org/10.1016/j.esr.2023.101111>

Data-driven, short-term prediction of charging station occupation. *Electricity*, 4(2), 134-153.

<https://doi.org/10.3390/electricity4020009>

[37] Shern, S. J., Sarker, M. T., Haram, M. H. S. M., Ramasamy, G., Thiagarajah, S. P., & Al Farid, F. (2024). Artificial Intelligence Optimization for User Prediction and Efficient Energy Distribution in Electric Vehicle Smart Charging Systems. *Energies*, 17(22), 5772. <https://doi.org/10.3390/en17225772>

[38] Kaur, R., Gabrijelčič, D., & Klobučar, T. (2023). Artificial intelligence for cybersecurity: Literature review and future research directions. *Information Fusion*, 97, 101804. <https://doi.org/10.1016/j.inffus.2023.101804>

[39] Paret, P., Finegan, D., & Narumanchi, S. (2023). Artificial intelligence for power electronics in electric vehicles: challenges and opportunities. *Journal of Electronic Packaging*, 145(3), 034501. <https://doi.org/10.1115/1.4056306>

[40] Arévalo, P., Ochoa-Correa, D., & Villa-Ávila, E. (2024). A systematic review on the integration of artificial intelligence into energy management systems for electric vehicles: Recent advances and future perspectives. *World Electric Vehicle Journal*, 15(8), 364. <https://doi.org/10.3390/wevj15080364>

[41] Mhlanga, D. (2023). Artificial intelligence and machine learning for energy consumption and production in emerging markets: a review. *Energies*, 16(2), 745. <https://doi.org/10.3390/en16020745>

[42] Wang, Q., Zhang, F., Li, R., & Sun, J. (2024). Does artificial intelligence promote energy transition and curb carbon emissions?

The role of trade openness. *Journal of Cleaner Production*, 447, 141298. <https://doi.org/10.1016/j.jclepro.2024.141298>

[43] Yao, Z., Lum, Y., Johnston, A., Mejia-Mendoza, L. M., Zhou, X., Wen, Y., ... & Seh, Z. W. (2023). Machine learning for a sustainable energy future. *Nature Reviews Materials*, 8(3), 202-215. <https://doi.org/10.1038/s41578-022-00490-5>

[44] Liu, Y., Chen, H., Zhang, L., & Feng, Z. (2021). Enhancing building energy efficiency using a random forest model: A hybrid prediction approach. *Energy Reports*, 7, 5003-5012. <https://doi.org/10.1016/j.egyr.2021.07.135>

[45] Nie, P., Roccotelli, M., Fanti, M. P., Ming, Z., & Li, Z. (2021). Prediction of home energy consumption based on gradient boosting regression tree. *Energy Reports*, 7, 1246-1255. <https://doi.org/10.1016/j.egyr.2021.02.006>

[46] Miraftabzadeh, S. M., Colombo, C. G., Longo, M., & Foiadelli, F. (2023). K-means and alternative clustering methods in modern power systems. *Ieee Access*, 11, 119596-119633. <http://dx.doi.org/10.1109/ACCESS.2023.3327640>

[47] Pierre, A. A., Akim, S. A., Semenyo, A. K., & Babiga, B. (2023). Peak electrical energy consumption prediction by ARIMA, LSTM, GRU, ARIMA-LSTM and ARIMA-GRU approaches. *Energies*, 16(12), 4739. <https://doi.org/10.3390/en16124739>

[48] Pratico, D., Laganá, F., Oliva, G., Fiorillo, A. S., Pullano, S. A., Calcagno, S., ... & La Foresta, F. (2024, July). Sensors and Integrated Electronic Circuits for Monitoring Machinery On Wastewater Treatment:

Artificial Intelligence Approach. In 2024 IEEE Sensors Applications Symposium (SAS) (pp. 1-6).

IEEE.

<https://scholar.google.com/citations?user=ccruDcsAAAAJ&hl=it>

Contribución de los Autores Individuales en la Elaboración de un Artículo Científico (Política de Ghostwriting)

Todos los autores participaron equitativamente del desarrollo del artículo.

Fuentes de Financiamiento para la Investigación Presentada en el Artículo Científico o para el Artículo Científico en sí

No se recibió financiación para la realización de este estudio.

Conflicto de Intereses

Los autores declaran no tener ningún conflicto de interés relevante con el contenido de este artículo.

Licencia de Atribución de Creative Commons 4.0 (Atribución 4.0 Internacional, CC BY 4.0)

Este artículo se publica bajo los términos de la Licencia de Atribución de Creative Commons 4.0.

<https://creativecommons.org/licenses/by/4.0/deed.es>