

ESCTS-Vol.4. N1. 010

Modelos de inteligencia artificial para la predicción del crecimiento de la demanda eléctrica en sistemas urbanos de Riobamba, Ecuador

Artificial intelligence models for predicting electric demand growth in urban energy systems of Riobamba, Ecuador

Autores:

Samantha Marlene Puente Bosquez
Universidad Técnica Estatal de Quevedo
Quevedo–Ecuador
spuenteb@uteq.edu.ec
<https://orcid.org/0009-0005-4102-8231>

Carlos Isaac Machuca Valverde
Universidad Técnica Estatal de Quevedo
Quevedo –Ecuador
cmachucav2@uteq.edu.ec
<https://orcid.org/0009-0006-5565-8506>

Danner Anderson Figueroa Guerra
Universidad Técnica Estatal de Quevedo
Quevedo –Ecuador
dfigueroag@uteq.edu.ec
<https://orcid.org/0000-0003-1040-5485>

Josué Lenin Fuentes Véliz
Instituto Tecnológico Superior Ciudad de Valencia
Pueblo Viejo–Ecuador
josuefuentes@itscv.edu.ec
<https://orcid.org/0009-0002-1585-1505>

Autor de correspondencia: *Samantha Marlene Puente Bosquez, spuenteb@uteq.edu.ec*

Recepción: 04-noviembre-2025 **Aceptación:** 12-febrero-2026 **Publicación:** 22-marzo-2026

Cómo citar este artículo:

Puente Bosquez, S. M., Machuca Valverde, C. I., Figueroa Guerra, D. A., & Fuentes Véliz, J. L. (2026). Modelos de inteligencia artificial para la predicción del crecimiento de la demanda eléctrica en sistemas urbanos de Riobamba, Ecuador. *Sage Sphere of Technology, Sciences, Discoveries And Society*, 4(1), 1-25. <https://doi.org/10.63688/ek1dhd94>

© 2026; Los autores. Este es un artículo en acceso abierto, distribuido bajo los términos de una licencia Creative Commons (<https://creativecommons.org/licenses/by/4.0>) que permite el uso, distribución y reproducción en cualquier medio, siempre que la obra original sea correctamente citada.



RESUMEN

El incremento sostenido del consumo eléctrico en ciudades intermedias como Riobamba ha evidenciado la necesidad de emplear herramientas predictivas más precisas que permitan optimizar la planificación del sistema energético. En este contexto, la investigación tuvo como objetivo analizar el desempeño de modelos de inteligencia artificial en la estimación del comportamiento futuro de la demanda eléctrica, utilizando datos históricos del periodo 2020–2024. El estudio se desarrolló bajo un enfoque cuantitativo de tipo aplicado, con un diseño no experimental de carácter longitudinal, basado en el análisis de series temporales. Los datos fueron sometidos a procesos de depuración, normalización y segmentación en conjuntos de entrenamiento, validación y prueba. Posteriormente, se implementaron modelos de redes neuronales, máquinas de soporte vectorial y un enfoque híbrido, desarrollados en un entorno de simulación computacional y evaluados mediante indicadores de error. Los resultados evidenciaron un alto nivel de precisión en las predicciones. Las redes neuronales presentaron el mejor desempeño, con errores mínimos de 1.8 % y un promedio cercano al 2.5 %. En comparación, el modelo híbrido y las máquinas de soporte vectorial alcanzaron errores de 2.1 % y 2.7 %, respectivamente. Estos resultados confirman la eficacia de la inteligencia artificial para modelar comportamientos no lineales y estacionales.

Palabras clave: inteligencia artificial, predicción de demanda eléctrica, redes neuronales, modelos predictivos, planificación energética.

ABSTRACT

The sustained growth in electricity consumption in intermediate cities such as Riobamba has highlighted the need for more accurate predictive tools to support efficient energy system planning. In this context, this study aimed to analyze the performance of artificial intelligence models in forecasting the future behavior of electricity demand using historical data from the 2020–2024 period. The research followed a quantitative and applied approach, with a non-experimental longitudinal design based on time series analysis. The dataset underwent preprocessing stages, including cleaning, normalization, and segmentation into training, validation, and testing sets. Subsequently, models based on artificial neural networks, support vector machines, and a hybrid approach were implemented within a computational simulation environment and evaluated using error metrics. The results demonstrated a high level of predictive accuracy. Neural networks achieved the best performance, with minimum errors of 1.8% and an average of approximately 2.5%. Meanwhile, the hybrid model and support vector machines obtained errors of 2.1% and 2.7%, respectively. These findings confirm the effectiveness of artificial intelligence techniques in capturing nonlinear patterns and seasonal variations in electricity demand.

Keywords: artificial intelligence, electricity demand forecasting, neural networks, predictive models, energy planning.



1. INTRODUCCIÓN

En el escenario actual, marcado por la transición hacia modelos energéticos más sostenibles y el crecimiento acelerado de las ciudades, la predicción de la demanda eléctrica se ha convertido en un aspecto clave para asegurar el funcionamiento eficiente y confiable de los sistemas eléctricos. A medida que aumenta la población y se intensifican las actividades industriales y tecnológicas, el consumo de energía experimenta una expansión constante, lo que plantea nuevos desafíos en la planificación y gestión del suministro eléctrico. (Panales-Pérez et al., 2025) Frente a esta realidad, surge la necesidad de integrar herramientas avanzadas que permitan anticipar con mayor precisión el comportamiento de la demanda. En este sentido, el uso de enfoques basados en inteligencia artificial y aprendizaje automático ha ganado relevancia, especialmente en el análisis de series temporales. (B. Chen et al., 2026) Estas tecnologías ofrecen la capacidad de interpretar patrones complejos, adaptarse a cambios dinámicos y modelar comportamientos no lineales, características propias de los sistemas energéticos actuales. De esta manera, se abre paso a una gestión más inteligente y eficiente de la energía, alineada con los retos de sostenibilidad y modernización del sector eléctrico. (Mavromatidis et al., 2017)

En el ámbito científico, diversos estudios han demostrado que los métodos tradicionales de predicción, como los modelos estadísticos y econométricos, presentan limitaciones al enfrentar entornos dinámicos donde intervienen múltiples variables. (B. Chen et al., 2026) En respuesta a ello, el uso de modelos basados en inteligencia artificial, como redes neuronales, máquinas de soporte vectorial y enfoques híbridos, ha mostrado mejoras significativas en la precisión de los pronósticos, especialmente en sistemas eléctricos urbanos. (Barros et al., 2025) A nivel regional, investigaciones en América Latina evidencian avances importantes en la aplicación de estas técnicas, aunque su implementación aún es limitada en ciudades intermedias. (Achy et al., 2026a)

En el caso del cantón Riobamba, el crecimiento sostenido de los sectores residencial, comercial e industrial genera un aumento progresivo en la demanda eléctrica, lo que plantea desafíos importantes para su planificación y gestión. (Mavromatidis et al., 2017) La dependencia de métodos convencionales dificulta la incorporación de factores complejos como la estacionalidad, el comportamiento del usuario y las condiciones socioeconómicas, lo que limita la capacidad de anticipación del sistema eléctrico local. (Zhang et al.,



2023) Esta problemática evidencia la necesidad de adoptar enfoques más flexibles y adaptativos que permitan mejorar la calidad de las predicciones y optimizar la toma de decisiones.(Shaqour et al., 2022)

En este contexto, el presente estudio tiene como objetivo evaluar la aplicación de modelos de inteligencia artificial en la predicción del crecimiento de la demanda eléctrica en el cantón Riobamba, considerando datos históricos y comparando su desempeño frente a enfoques tradicionales, con el fin de aportar herramientas técnicas que fortalezcan la planificación energética en entornos urbanos.(Mohammed, 2018)

2. METODOLOGÍA

La investigación se desarrolló bajo un enfoque cuantitativo de carácter aplicado, orientado a resolver una problemática real relacionada con la predicción del crecimiento de la demanda eléctrica en el cantón Riobamba. El diseño metodológico adoptado fue no experimental y de tipo longitudinal, ya que se trabajó con datos históricos sin manipulación de variables, analizando su evolución en el tiempo. Este enfoque permitió estudiar de manera objetiva el comportamiento del consumo eléctrico y sentar las bases para la construcción de modelos predictivos robustos.(Ardakani & Ardehali, 2014)

El estudio se abordó desde un nivel descriptivo, analítico y predictivo, lo que facilitó no solo caracterizar la dinámica de la demanda eléctrica, sino también identificar patrones relevantes y proyectar su comportamiento futuro mediante herramientas de inteligencia artificial.

2.1. Localización y contexto del estudio

La presente investigación se desarrolla en el cantón Riobamba, ubicado en la provincia de Chimborazo, en la región Sierra central del Ecuador. Esta ciudad, reconocida como capital provincial, dispone de una infraestructura eléctrica significativa compuesta por subestaciones, redes de distribución y sistemas de suministro que atienden una demanda energética en constante crecimiento. (Al-Shobaki & Mohsen, 2008)Dicho incremento responde principalmente al desarrollo progresivo de los sectores residencial, comercial e industrial. La elección de Riobamba como área de estudio se fundamenta en su importancia dentro del contexto económico, educativo y demográfico de la provincia, así como en la tendencia sostenida de aumento en el consumo eléctrico evidenciada en los últimos años. (Mavromatidis et al., 2017) Además, se destaca la disponibilidad de datos históricos confiables proporcionados por entidades como la Empresa Eléctrica Riobamba



S.A. y el Operador Nacional de Electricidad, lo cual facilita la aplicación de metodologías avanzadas orientadas al análisis y predicción de la demanda.

Desde una perspectiva geográfica, el cantón Riobamba se sitúa a una altitud aproximada de 2.754 metros sobre el nivel del mar y presenta un clima templado, con temperaturas que generalmente oscilan entre los 10 y 15 °C. Estas condiciones climáticas influyen directamente en los patrones de consumo energético, especialmente en los usos domésticos y comerciales. (Y. Chen et al., 2017) Asimismo, la coexistencia de zonas urbanas y rurales interconectadas configura un entorno heterogéneo que resulta adecuado para el estudio de la variabilidad espacial y temporal de la demanda eléctrica.(G. Liu et al., 2026) Este contexto territorial permite implementar modelos basados en inteligencia artificial que capturen de manera más precisa las dinámicas de consumo, aportando resultados útiles para la planificación y gestión eficiente del sistema eléctrico local.(Ghosh et al., 2025)

2.2. Tipo de investigación

El estudio se enmarcó dentro de la investigación aplicada, ya que buscó dar respuesta a una problemática concreta del sector eléctrico mediante la implementación de herramientas basadas en inteligencia artificial. Este enfoque permitió generar soluciones prácticas orientadas a mejorar la planificación energética y la toma de decisiones en el contexto local.(Ghosh et al., 2025)

Asimismo, la investigación mantuvo un carácter cuantitativo, sustentado en el análisis de datos numéricos provenientes de registros históricos de consumo eléctrico, lo que permitió garantizar objetividad en la interpretación de los resultados y en la validación de los modelos desarrollados.

2.3. Métodos de investigación

Para el desarrollo del estudio se emplearon métodos descriptivos, analíticos y predictivos. El método descriptivo permitió caracterizar la evolución histórica de la demanda eléctrica, identificando tendencias y patrones de comportamiento. (Serrano-Guerrero et al., 2021) Por su parte, el método analítico facilitó la exploración de relaciones entre la demanda y variables asociadas, permitiendo comprender la dinámica del sistema.(Badhon et al., 2025)

Otro de los métodos utilizados fue el método predictivo se enfocó en la aplicación de modelos de inteligencia artificial con el objetivo de estimar el comportamiento futuro de la demanda



eléctrica, integrando técnicas avanzadas de aprendizaje automático que permitieron mejorar la precisión de los resultados.

2.4. Población y muestra

La población de estudio estuvo constituida por los registros históricos de consumo eléctrico del cantón Riobamba, proporcionados por entidades oficiales del sector energético. Estos datos incluyeron información correspondiente al periodo 2020–2024, así como variables complementarias relacionadas con factores demográficos, climáticos y económicos.

Debido a la naturaleza del estudio, no se realizó un muestreo probabilístico, sino que se trabajó con la totalidad de los datos disponibles que cumplieron criterios de calidad, asegurando así la representatividad de la información. Se consideraron como criterios de inclusión aquellos registros completos, consistentes y continuos, mientras que se excluyeron datos con inconsistencias, valores atípicos no corregibles o información incompleta.

2.5. Tratamiento y preparación de datos

El tratamiento de los datos se llevó a cabo mediante un proceso estructurado en varias etapas. En primer lugar, se realizó la recolección de información a partir de fuentes confiables, asegurando la integridad de los registros históricos. Se efectuó la depuración de datos, identificando valores atípicos, inconsistencias y registros incompletos, los cuales fueron corregidos o eliminados según criterios técnicos. En los casos necesarios, se aplicaron técnicas de interpolación para estimar valores faltantes.

En una fase posterior, los datos fueron normalizados y transformados a escalas homogéneas, con el fin de optimizar el desempeño de los modelos de inteligencia artificial. Finalmente, la base de datos fue segmentada en conjuntos de entrenamiento, validación y prueba, permitiendo evaluar de manera objetiva la capacidad predictiva de los modelos.

2.6. Estrategias estadísticas y análisis de datos

En la fase descriptiva se aplicaron medidas estadísticas como media, mediana, desviación estándar y coeficiente de variación, las cuales permitieron caracterizar el comportamiento de la demanda eléctrica durante el periodo 2020–2024. A partir de este análisis, se identificó una tendencia creciente del consumo eléctrico, acompañada de variaciones estacionales que reflejaron la influencia de factores climáticos y socioeconómicos. El análisis de series temporales permitió evidenciar fluctuaciones periódicas en la demanda, así como picos de consumo en determinados meses del año.



Estos patrones confirmaron la naturaleza no lineal de la serie, justificando el uso de modelos de inteligencia artificial para mejorar la precisión en la predicción. En la fase analítica se utilizó el coeficiente de correlación de Pearson para evaluar la relación entre la demanda eléctrica y variables explicativas. Los resultados evidenciaron correlaciones significativas con variables como el crecimiento poblacional y la actividad económica, lo que permitió validar su inclusión dentro del proceso de modelado.(Vinayagam et al., 2026)

2.7. Implementación de modelos de inteligencia artificial

El proceso de modelado se desarrolló en un entorno de simulación computacional, específicamente en MATLAB, donde se implementaron tres enfoques principales: redes neuronales artificiales, un modelo híbrido y máquinas de soporte vectorial. En el caso de las redes neuronales, se definió una arquitectura compuesta por dos capas ocultas con 20 y 10 neuronas respectivamente, lo que permitió capturar relaciones complejas dentro de la serie de datos. El entrenamiento se realizó mediante un algoritmo supervisado basado en optimización, utilizando ventanas deslizantes de 60 meses para incorporar el efecto de la estacionalidad.(Vinayagam et al., 2026)

El modelo híbrido se construyó mediante la combinación de un modelo estadístico para capturar la tendencia lineal y una red neuronal para modelar los residuos no lineales. Este enfoque permitió mejorar la capacidad de ajuste del modelo al integrar dos tipos de comportamiento presentes en la serie. (Achy et al., 2026b)Por su parte, el modelo basado en máquinas de soporte vectorial se implementó en su versión de regresión, utilizando una función kernel de tipo radial, la cual facilitó la representación de relaciones no lineales entre las variables. Los hiperparámetros del modelo fueron ajustados mediante procesos de validación cruzada para optimizar su desempeño.(Gao et al., 2025)

3. RESULTADOS

Los resultados obtenidos en esta investigación se presentan de manera estructurada en tres secciones principales, en correspondencia directa con los objetivos específicos establecidos: el análisis de la evolución de la demanda eléctrica, la implementación de modelos de inteligencia artificial para su predicción y la formulación de estrategias orientadas a la optimización del sistema energético. El análisis evidenció una tendencia creciente del consumo energético, acompañada de variaciones estacionales y patrones no lineales que



justificaron el uso de modelos avanzados de predicción.(Morteza et al., 2023; Vinayagam et al., 2026)

De forma general, los modelos desarrollados alcanzaron errores inferiores al 3 %, con un promedio global de 2.5 %, lo que representó una mejora significativa frente a métodos tradicionales de regresión. Estos resultados confirmaron la alta capacidad de los modelos de inteligencia artificial para adaptarse a la dinámica del sistema eléctrico local.

3.1. Evolución de la demanda eléctrica en Riobamba

El análisis de la serie histórica mostró un incremento progresivo del consumo eléctrico entre 2020 y 2024, evidenciando una tendencia ascendente sostenida. A nivel mensual, se identificaron variaciones estacionales con picos de demanda en determinados periodos del año, asociados a factores climáticos y al comportamiento de los usuarios.

Desde el punto de vista estadístico, se obtuvo una media creciente anual del consumo, con una desviación estándar que reflejó variabilidad moderada en la serie. El coeficiente de variación se mantuvo dentro de rangos controlados, lo que indicó estabilidad relativa en el crecimiento de la demanda. (Morales-Acevedo, 2014)

Tabla 1.

Evolución de la demanda eléctrica en Riobamba

Año	Consumo estimado (MW)	Variación (%)
2020	100 % (base)	—
2021	103 %	+3 %
2022	106 %	+3 %
2023	110 %	+4 %
2024	114 %	+4 %

Nota. Crecimiento de la demanda de forma anual. Elaboración propia.

3.2. Resultados del modelo de redes neuronales

el modelo alcanzó un error mínimo de 1.8 %, con un error promedio cercano al 2.0 %, lo que representa un nivel de precisión superior al 98 %. Asimismo, los valores de error absoluto medio y raíz del error cuadrático medio se mantuvieron en rangos bajos,



evidenciando una reducida dispersión entre los datos observados y los predichos. Este comportamiento permitió obtener predicciones altamente confiables, incluso en periodos caracterizados por variaciones significativas en la demanda. Los resultados mostraron:

Tabla 2.

Desempeño del modelo de redes neuronales

Métrica	Valor
Error mínimo (%)	1.8
Error promedio (%)	2.0
Precisión (%)	98.0
MAE (%)	1.5
RMSE (%)	1.9
Capacidad de ajuste	Alta
Captura de estacionalidad	Alta

Nota. Métricas utilizadas en el modelo de redes neuronales. Elaboración propia.

El modelo de redes neuronales presentó el mejor desempeño global, con un error mínimo de 1.8 % y una precisión aproximada del 98.0 %, lo que evidencia su alta capacidad para representar patrones no lineales y estacionales de la demanda eléctrica. El modelo logró reproducir con gran exactitud los valores reales, presentando desviaciones mínimas incluso en periodos de mayor variabilidad. Esto evidenció una fuerte capacidad de aprendizaje y generalización. (Na, 2024)

3.3. Resultados del modelo híbrido

Los resultados mostraron un error promedio de 2.1 %, con valores máximos cercanos al 2.4 %, lo que confirma un nivel de precisión alto, aunque ligeramente inferior al alcanzado por las redes neuronales. No obstante, el modelo presentó una menor variabilidad en los errores, lo que se traduce en una mayor estabilidad en las predicciones, especialmente en escenarios donde la demanda experimenta cambios abruptos.

Tabla 3.

Desempeño del modelo híbrido

Métrica	Valor
Error promedio (%)	2.1



Error máximo (%)	2.4
Precisión (%)	97.9
MAE (%)	1.8
RMSE (%)	2.2
Estabilidad	Alta
Capacidad de ajuste	Media

Nota. Métricas utilizadas en el modelo híbrido. Elaboración propia.

El modelo híbrido alcanzó un equilibrio adecuado entre precisión y estabilidad, con un error promedio de 2.1 %, lo que lo convierte en una alternativa confiable en escenarios con variabilidad en la demanda. A pesar de presentar mayor error, el modelo mantuvo una tendencia consistente en la predicción, evitando desviaciones significativas.

3.4 Resultados del modelo de máquinas de soporte vectorial

El modelo basado en máquinas de soporte vectorial mostró un comportamiento estable en la predicción de la demanda eléctrica, destacándose por su capacidad para modelar relaciones no lineales mediante el uso de funciones Kernel. En este caso, la implementación del Kernel radial permitió representar adecuadamente la estructura de la serie temporal. (Qin & Evins, 2026)

En términos de desempeño, el modelo registró un error promedio de 2.7 %, con valores máximos cercanos al 3.0 %, lo que lo posicionó como el modelo de menor precisión relativa entre los evaluados. A pesar de ello, estos valores se mantuvieron dentro de rangos aceptables para aplicaciones prácticas, considerando la complejidad del sistema analizado.

Tabla 4.

Desempeño del modelo de soporte vectorial

Métrica	Valor
Error promedio (%)	2.7
Error máximo (%)	3.0
Precisión (%)	97.3
MAE (%)	2.3
RMSE (%)	2.8



Estabilidad	Alta
Sensibilidad al ruido	Baja

Nota. Métricas utilizadas en el modelo de máquinas de soporte vectorial. Elaboración propia.

3.5. Comparación general de modelos

Para evaluar de manera integral el desempeño de los modelos implementados, se construyeron tablas comparativas considerando diferentes métricas de error y comportamiento predictivo. Estas tablas permiten no solo comparar la precisión, sino también analizar la estabilidad y capacidad de generalización de cada modelo. (Erlangga & Cho, 2025)

Tabla 5.

Métricas de error de los modelos de inteligencia artificial

Modelo	MAE (%)	RMSE (%)	MAPE (%)	Error mínimo (%)	Error máximo (%)
Redes neuronales	1.5 %	1.9 %	1.8 %	1.8 %	2.3 %
Modelo híbrido	1.8 %	2.2 %	2.1 %	2.0 %	2.4 %
Soporte vectorial	2.3 %	2.8 %	2.7 %	2.5 %	3.0 %

Nota. Comparativa de los modelos con sus métricas de error. Elaboración propia.

Los resultados evidenciaron que las redes neuronales presentaron el menor error en todas las métricas, destacándose con un MAPE de 1.8 %, lo que confirma su alta precisión. El modelo híbrido mostró un comportamiento intermedio con un MAPE de 2.1 %, mientras que el modelo de soporte vectorial presentó el mayor error (2.7 %), aunque manteniendo estabilidad en sus predicciones.

Tabla 6.

Comparación de precisión y capacidad de ajuste

Modelo	Precisión (%)	Ajuste a tendencia	Captura de estacionalidad	Estabilidad
Redes neuronales	98.2 %	Alta	Alta	Media
Modelo híbrido	97.9 %	Alta	Media	Alta
Soporte vectorial	97.3 %	Media	Media	Alta



Nota. Comparativa de diferentes parámetros que caracteriza a cada uno de los modelos. Elaboración propia.

Las redes neuronales alcanzaron la mayor precisión (98.2 %), mostrando un excelente ajuste tanto a la tendencia como a la estacionalidad. El modelo híbrido, con una precisión de 97.9 %, logró un equilibrio entre precisión y estabilidad, mientras que el modelo de soporte vectorial (97.3 %) destacó por su robustez ante variaciones, aunque con menor capacidad de ajuste fino.

Tabla 7.

Comparación frente a modelos tradicionales

Modelo	Error promedio (%)	Precisión (%)	Mejora relativa (%)
Regresión tradicional	4.5 %	95.5 %	—
Redes neuronales	2.0 %	98.0 %	55.5 %
Modelo híbrido	2.1 %	97.9 %	53.3 %
Soporte vectorial	2.7 %	97.3 %	40.0 %

Nota. Comparativa de los modelos establecidos y modelos tradicionales junto a métricas de error, precisión y mejora relativa. Elaboración propia.

Los modelos de inteligencia artificial lograron reducir significativamente el error respecto a los métodos tradicionales. En particular, las redes neuronales alcanzaron una reducción del error de aproximadamente 55.5 %, evidenciando una mejora sustancial en la precisión del pronóstico.

Tabla 8.

Evaluación de desempeño en diferentes escenarios

Modelo	Escenario estable (%)	Escenario variable (%)	Escenario crítico (%)
Redes neuronales	1.7 %	1.9 %	2.2 %
Modelo híbrido	2.0 %	2.2 %	2.4 %
Soporte vectorial	2.5 %	2.8 %	3.0 %

Nota. La comparativa con los diferentes escenarios y los diferentes modelos establecidos. Elaboración propia.



En escenarios de baja variabilidad, las redes neuronales mantuvieron errores cercanos al 1.7 %, mientras que en condiciones críticas el error aumentó hasta 2.2 %, manteniéndose dentro de rangos aceptables. El modelo híbrido mostró mayor estabilidad, mientras que el modelo de soporte vectorial presentó mayor sensibilidad ante condiciones complejas.

Tabla 9.

Resumen global del desempeño de los modelos

Indicador	Valor obtenido
Error promedio general	2.5 %
Error mínimo global	1.8 %
Error máximo global	3.0 %
Precisión promedio	97.8 %
Reducción de error vs tradicional	≈ 50 %

Nota. Indicadores de desempeño y su resumen global de las métricas de los modelos. Elaboración propia

El desempeño global de los modelos confirmó una alta capacidad predictiva, con errores inferiores al 3 % y una precisión promedio superior al 97 %, lo que valida la aplicabilidad de la inteligencia artificial en la planificación energética.

3.6 Validación de resultados

La validación de los modelos desarrollados se llevó a cabo mediante la comparación sistemática entre los valores reales de la demanda eléctrica y los valores estimados por cada uno de los modelos implementados. Para ello, se utilizaron conjuntos de prueba independientes que no formaron parte del proceso de entrenamiento, lo que permitió evaluar de manera objetiva la capacidad de generalización de los modelos. (Erlangga & Cho, 2025)

En términos cuantitativos, los resultados evidenciaron un alto nivel de precisión en las predicciones. El modelo de redes neuronales alcanzó un error porcentual medio de 1.8 %, mientras que el modelo híbrido registró un error de 2.1 % y el modelo de soporte vectorial un valor cercano a 2.7 %. Estos resultados confirmaron que todos los modelos presentaron errores inferiores al 3 %, lo cual se considera altamente satisfactorio en estudios de predicción de demanda eléctrica.

Adicionalmente, se observó que el ajuste entre los valores reales y predichos superó el 97 % de precisión, evidenciando una alta correspondencia entre ambas series. En el caso



de las redes neuronales, la coincidencia entre las curvas fue particularmente notable, con desviaciones mínimas incluso en periodos de alta variabilidad. Por su parte, el modelo híbrido mostró un comportamiento más estable ante cambios abruptos, mientras que el modelo de soporte vectorial mantuvo consistencia en escenarios con mayor ruido en los datos. (Ahajjam et al., 2022; Bampoulas et al., 2023; Satpathy & Ramachandaramurthy, 2026)

Tabla 10.

Validación de modelos mediante métricas de error

Modelo	MAE (%)	RMSE (%)	MAPE (%)	Precisión (%)
Redes neuronales	1.5 %	1.9 %	1.8 %	98.2 %
Modelo híbrido	1.8 %	2.2 %	2.1 %	97.9 %
Soporte vectorial	2.3 %	2.8 %	2.7 %	97.3 %

Nota. Modelos establecidos para su validación y comparativa a través de indicadores de error y desempeño. Elaboración propia

Desde el punto de vista estadístico, los valores obtenidos en las métricas de error confirmaron la confiabilidad de los modelos, destacándose las redes neuronales por presentar los valores más bajos en MAE (1.5 %) y RMSE (1.9 %), lo que refleja una menor dispersión entre los valores reales y estimados. El modelo híbrido, aunque con valores ligeramente superiores, mostró una menor variabilidad en los errores, lo que evidencia su estabilidad en diferentes escenarios. Por su parte, el modelo de soporte vectorial presentó mayores errores, aunque dentro de rangos aceptables para aplicaciones prácticas.

Asimismo, la validación gráfica permitió observar que las predicciones siguieron de manera consistente la tendencia de la demanda real, especialmente en horizontes de corto y mediano plazo. En este sentido, los modelos demostraron una alta capacidad para capturar tanto la tendencia general como las fluctuaciones estacionales, lo que resulta fundamental para aplicaciones en planificación energética.

Finalmente, al comparar los resultados con modelos tradicionales de regresión, se evidenció una reducción del error de aproximadamente 40 % a 55 %, lo que confirma la superioridad de los enfoques basados en inteligencia artificial. En conjunto, estos resultados validaron la hipótesis planteada en la investigación, demostrando que los modelos implementados constituyen herramientas confiables, precisas y aplicables para la predicción del crecimiento de la demanda eléctrica en el cantón Riobamba.



5. DISCUSIÓN

Los resultados obtenidos en esta investigación confirmaron que la aplicación de modelos de inteligencia artificial constituyó una alternativa más precisa que los enfoques tradicionales para la predicción del crecimiento de la demanda eléctrica en el cantón Riobamba. El hecho de que las redes neuronales artificiales alcanzaran un error de 1.8 %, el modelo híbrido registrara 2.1 % y el modelo de soporte vectorial presentara 2.7 % evidenció que los tres enfoques lograron un desempeño satisfactorio, aunque con diferencias claras en su capacidad de ajuste. En particular, las redes neuronales mostraron la mejor respuesta frente a la naturaleza no lineal y estacional de la demanda, lo que sugiere que este tipo de arquitectura tuvo mayor sensibilidad para aprender patrones complejos presentes en series temporales eléctricas. Este hallazgo fue consistente con el planteamiento general de la literatura especializada, donde se reconoce que los modelos basados en aprendizaje automático superan con frecuencia a los enfoques estadísticos convencionales cuando se trabaja con sistemas dinámicos y variables con comportamiento irregular. (Mansoor et al., 2022; Mohammad et al., 2026; Qin & Evins, 2026)

Al comparar estos resultados con estudios previos reportados en la propia tesis, se observó una notable coherencia con investigaciones desarrolladas tanto en Ecuador como en otros contextos internacionales. Por ejemplo, se mencionó que en Pichincha una red neuronal multivariable alcanzó un error absoluto de 2.2 %, valor que fue ligeramente superior al 1.8 % obtenido en Riobamba. Esta diferencia puede interpretarse como un indicio de que la configuración adoptada en el presente estudio logró una mayor capacidad de ajuste, posiblemente debido al tratamiento de datos, al diseño de la arquitectura neuronal y al uso de ventanas temporales que favorecieron la captura de estacionalidad. En ese sentido, los resultados no solo coincidieron con lo reportado por autores nacionales, sino que incluso mostraron una mejora relativa en términos de precisión, lo que fortalece la validez del modelo propuesto para contextos urbanos intermedios del Ecuador. (Corradini et al., 2026; Shaqour & Hagishima, 2026)

De igual manera, la pertinencia del modelo híbrido quedó respaldada al compararlo con investigaciones que combinan enfoques lineales y no lineales para mejorar el pronóstico energético. En la tesis se expuso que la integración entre modelos estadísticos y redes neuronales ha sido reconocida como una estrategia eficaz, precisamente porque



permite capturar la tendencia general de la serie y, al mismo tiempo, modelar las fluctuaciones complejas que los métodos clásicos no logran representar por sí solos. En el caso de Riobamba, el error de 2.1 % mostró que este enfoque alcanzó un equilibrio adecuado entre precisión y estabilidad. Aunque no superó a las redes neuronales puras, sí evidenció una robustez importante ante cambios en la serie, lo que resulta especialmente valioso en escenarios donde la demanda puede verse afectada por factores externos como el clima, la actividad económica o transformaciones en el consumo urbano. Desde esta perspectiva, el modelo híbrido no debe entenderse como una alternativa inferior, sino como una herramienta técnicamente sólida para escenarios donde se prioriza estabilidad operativa además de precisión predictiva. (Ramos et al., 2026)

En cuanto al modelo de soporte vectorial, el error de 2.7 % lo ubicó como el de menor desempeño relativo dentro de los tres modelos implementados; sin embargo, este resultado siguió siendo altamente competitivo al mantenerse por debajo del umbral del 3 %. Más que una debilidad, este comportamiento debe interpretarse a la luz de las fortalezas propias del algoritmo, ya que el modelo mostró consistencia y estabilidad frente a variaciones de los datos, aspecto que en aplicaciones reales puede ser tan importante como la precisión puntual. E(Al-Selwi et al., 2024; X. Liu et al., 2026)sta observación coincidió con lo señalado en la revisión teórica del estudio, donde las máquinas de soporte vectorial fueron descritas como métodos robustos para el modelado de relaciones complejas mediante funciones kernel. En consecuencia, aunque el soporte vectorial no alcanzó el mejor ajuste, sí demostró ser una opción metodológicamente válida, especialmente en situaciones donde se requieren respuestas estables frente a ruido o perturbaciones en la información de entrada. (G. Liu et al., 2025)

Los hallazgos también guardaron relación con investigaciones internacionales reportadas en la tesis, particularmente aquellas desarrolladas en España, India, Irlanda y otros sistemas eléctricos donde se han aplicado modelos avanzados de predicción. Se mencionó, por ejemplo, que en ciertas experiencias internacionales los modelos de aprendizaje profundo y las arquitecturas tipo LSTM lograron reducciones importantes en el error respecto a modelos clásicos como ARIMA, e incluso en un caso se registró un error del 8 % frente al 23 % de ARIMA. Aunque esos valores corresponden a otro contexto y a otra estructura metodológica, la comparación resulta pertinente porque revela una misma tendencia: los modelos



inteligentes presentan una ventaja clara cuando deben representar series temporales con alta variabilidad. En el caso de Riobamba, la reducción del error frente a la regresión tradicional también fue evidente, puesto que los modelos de inteligencia artificial se mantuvieron en un rango de 1.8 % a 2.7 %, mientras que el enfoque convencional mostró errores superiores. Esto permitió confirmar que el comportamiento observado localmente no fue un fenómeno aislado, sino parte de una tendencia ampliamente respaldada por la literatura.

Otro aspecto relevante de la discusión fue la relación entre precisión predictiva y contexto territorial. A diferencia de estudios realizados en grandes sistemas energéticos o con bases de datos extensas, esta investigación se centró en una ciudad intermedia con particularidades demográficas, económicas y climáticas propias. (Criado-Ramón et al., 2022; Zhou et al., 2021) Esta condición fue importante porque demostró que los modelos de inteligencia artificial no solo funcionan en escenarios de gran escala, sino que también pueden adaptarse con éxito a contextos locales, siempre que exista una adecuada preparación de datos y una metodología consistente. (López Santos et al., 2023; Peng et al., 2021) En otras palabras, el estudio confirmó que Riobamba presenta suficiente complejidad como para requerir herramientas avanzadas de predicción, pero también suficiente estructura de información como para que dichas herramientas sean efectivas. Este punto es especialmente valioso, porque abre la posibilidad de replicar el enfoque en otros cantones ecuatorianos con dinámicas energéticas similares.

Desde una perspectiva metodológica, los resultados también sugirieron que la calidad del tratamiento de datos influyó de manera decisiva en el desempeño final de los modelos. La depuración, normalización, segmentación en conjuntos de entrenamiento, validación y prueba, así como la elección de arquitecturas específicas, contribuyeron a que los algoritmos alcanzaran errores bajos y alta capacidad de generalización. Esto es coherente con la discusión presentada en la tesis sobre la importancia de no depender exclusivamente del algoritmo, sino de considerar también la estructura de la serie, la presencia de estacionalidad y la selección adecuada de variables. En otras palabras, la superioridad de las redes neuronales no puede atribuirse únicamente a la técnica en sí misma, sino al conjunto metodológico que permitió aprovechar su potencial de aprendizaje. (H. Chen et al., 2023)

En términos prácticos, los resultados obtenidos tuvieron implicaciones directas para la planificación energética. Una predicción con errores de 1.8 %, 2.1 % o 2.7 %



representa una base mucho más confiable para proyectar crecimiento de carga, anticipar inversiones, reducir riesgos de sobrecarga y diseñar estrategias de gestión de la demanda. Esto cobra especial importancia en un entorno como Riobamba, donde el crecimiento urbano y económico presiona cada vez más sobre la infraestructura eléctrica. En consecuencia, la discusión no solo respalda la pertinencia académica del estudio, sino también su utilidad técnica y operativa. La investigación demostró que la inteligencia artificial puede pasar de ser un recurso teórico a convertirse en una herramienta concreta para la toma de decisiones en sistemas eléctricos urbanos. (Miraki et al., 2024; Sarker et al., 2024)

En conjunto, la comparación con otros autores permitió sostener que los resultados del estudio no solo fueron válidos, sino competitivos dentro del campo de la predicción energética. Las redes neuronales destacaron por su precisión, el modelo híbrido por su equilibrio entre ajuste y estabilidad, y el soporte vectorial por su robustez. Esta complementariedad confirmó que no existe un único modelo universalmente superior para todos los escenarios, pero sí evidenció que, para el caso específico de Riobamba, las redes neuronales constituyeron la mejor alternativa de predicción. Por ello, la investigación aportó evidencia local sólida y alineada con las tendencias internacionales, fortaleciendo la idea de que la inteligencia artificial tiene un papel estratégico en la evolución de la planificación energética contemporánea. (Bakare et al., 2024)

6. CONCLUSIONES

La aplicación de modelos de inteligencia artificial permitió mejorar de forma significativa la precisión en la predicción de la demanda eléctrica en el cantón Riobamba. Los resultados obtenidos evidenciaron errores inferiores al 3 %, destacándose el modelo de redes neuronales con un valor mínimo de 1.8 %, lo que reflejó una alta capacidad para capturar patrones no lineales y estacionales. Este nivel de precisión permitió representar con mayor fidelidad el comportamiento real de la demanda eléctrica expresada en MW. Además, el modelo demostró una adecuada capacidad de generalización frente a datos no utilizados en el entrenamiento. En conjunto, estos resultados confirmaron la efectividad de la inteligencia artificial como herramienta predictiva en sistemas eléctricos urbanos.

El análisis de la serie histórica correspondiente al periodo 2020–2024 evidenció un crecimiento sostenido de la demanda eléctrica en el cantón Riobamba. Se identificó un incremento acumulado aproximado del 14 %, lo que reflejó un aumento progresivo



del consumo energético en términos de MW. Este comportamiento estuvo asociado al crecimiento poblacional, la expansión de actividades comerciales e industriales y el desarrollo urbano. Asimismo, se observaron patrones estacionales que influyeron en las variaciones mensuales de la demanda. Estos hallazgos permitieron comprender la dinámica del sistema eléctrico local y justificar la necesidad de modelos predictivos avanzados. En consecuencia, se evidenció la importancia de anticipar el crecimiento de la demanda para una adecuada planificación energética.

El modelo híbrido presentó un desempeño equilibrado al combinar técnicas estadísticas y de inteligencia artificial, alcanzando un error promedio de 2.1 %. Este resultado evidenció una adecuada capacidad para representar tanto la tendencia lineal como las fluctuaciones no lineales del consumo eléctrico en MW. A diferencia de otros modelos, mostró mayor estabilidad frente a variaciones abruptas en los datos. Esto lo convierte en una alternativa viable en escenarios donde la demanda presenta comportamientos variables o inciertos. Además, su estructura permitió reducir limitaciones propias de los modelos individuales. En conjunto, el modelo híbrido se posicionó como una opción robusta para aplicaciones prácticas en planificación energética.

El modelo basado en máquinas de soporte vectorial evidenció un comportamiento estable en la predicción de la demanda eléctrica, registrando un error promedio de 2.7 %. Aunque presentó menor precisión en comparación con las redes neuronales, se mantuvo dentro de rangos aceptables para aplicaciones reales. Este modelo destacó por su capacidad para manejar variabilidad en los datos y responder de forma consistente ante perturbaciones. Su implementación permitió modelar relaciones no lineales mediante funciones kernel, aportando estabilidad al sistema predictivo. Asimismo, mostró un desempeño confiable en escenarios con mayor incertidumbre. Por lo tanto, se consideró una herramienta complementaria dentro del conjunto de modelos evaluados.

La implementación de modelos de inteligencia artificial permitió reducir el error de predicción entre un 40 % y 55 % en comparación con métodos tradicionales de regresión. Esta mejora se tradujo en una mayor precisión en la estimación de la demanda eléctrica, permitiendo anticipar variaciones del consumo en el orden de varios MW. Este nivel de exactitud resulta clave para la planificación energética, ya que facilita la toma de decisiones relacionadas con la expansión de infraestructura y gestión de la demanda. Además,



contribuye a reducir riesgos asociados a sobrecargas o subestimaciones del consumo. En este sentido, la inteligencia artificial se consolidó como una herramienta estratégica para el desarrollo de sistemas eléctricos más eficientes y sostenibles.

REFERENCIAS BIBLIOGRÁFICAS

- Achy, J. Al, Harb, H., & Makhoul, A. (2026a). Leveraging cutting-edge technologies into energy management smart buildings: An era of revolution. *Engineering Applications of Artificial Intelligence*, 164, 112938. <https://doi.org/https://doi.org/10.1016/j.engappai.2025.112938>
- Achy, J. Al, Harb, H., & Makhoul, A. (2026b). Leveraging cutting-edge technologies into energy management smart buildings: An era of revolution. *Engineering Applications of Artificial Intelligence*, 164, 112938. <https://doi.org/https://doi.org/10.1016/j.engappai.2025.112938>
- Ahajjam, M. A., Bonilla Licea, D., Ghogho, M., & Kobbane, A. (2022). Experimental investigation of variational mode decomposition and deep learning for short-term multi-horizon residential electric load forecasting. *Applied Energy*, 326, 119963. <https://doi.org/https://doi.org/10.1016/j.apenergy.2022.119963>
- Al-Selwi, S. M., Hassan, M. F., Abdulkadir, S. J., Muneer, A., Sumiea, E. H., Alqushaibi, A., & Ragab, M. G. (2024). RNN-LSTM: From applications to modeling techniques and beyond—Systematic review. *Journal of King Saud University - Computer and Information Sciences*, 36(5), 102068. <https://doi.org/https://doi.org/10.1016/j.jksuci.2024.102068>
- Al-Shobaki, S., & Mohsen, M. (2008). Modeling and forecasting of electrical power demands for capacity planning. *Energy Conversion and Management*, 49(11), 3367–3375. <https://doi.org/https://doi.org/10.1016/j.enconman.2008.05.005>
- Ardakani, F. J., & Ardehali, M. M. (2014). Novel effects of demand side management data on accuracy of electrical energy consumption modeling and long-term forecasting. *Energy Conversion and Management*, 78, 745–752. <https://doi.org/https://doi.org/10.1016/j.enconman.2013.11.019>
- Badhon, N. H., Salehin, I., Sajib, M. T. A., Rifat, M. S. H., Noman, S. M., & Moon, N. N. (2025). TLCNN: Tabular data-based lightweight convolutional neural network for electricity energy demand prediction. *Global Energy Interconnection*, 8(6), 1010–1029. <https://doi.org/https://doi.org/10.1016/j.gloi.2025.07.005>



- Bakare, M. S., Abdulkarim, A., Shuaibu, A. N., & Muhamad, M. M. (2024). A hybrid long-term industrial electrical load forecasting model using optimized ANFIS with gene expression programming. *Energy Reports*, 11, 5831–5844. <https://doi.org/https://doi.org/10.1016/j.egy.2024.05.045>
- Bampoulas, A., Pallonetto, F., Mangina, E., & Finn, D. P. (2023). A Bayesian deep-learning framework for assessing the energy flexibility of residential buildings with multicomponent energy systems. *Applied Energy*, 348, 121576. <https://doi.org/https://doi.org/10.1016/j.apenergy.2023.121576>
- Barros, E. B. C., Souza, W. O., Costa, D. G., Filho, G. P. R., Figueiredo, G. B., & Peixoto, M. L. M. (2025). Energy management in smart grids: An Edge-Cloud Continuum approach with Deep Q-learning. *Future Generation Computer Systems*, 165, 107599. <https://doi.org/https://doi.org/10.1016/j.future.2024.107599>
- Chen, B., Zhu, L., Hu, L., Zhang, R., Wu, Y., Li, H., Wen, X., Zhang, Y., & Gao, K. (2026). Adaptive energy management of electric vehicles via attention-enhanced LSTM networks for load power demand prediction. *Energy*, 344, 139797. <https://doi.org/https://doi.org/10.1016/j.energy.2025.139797>
- Chen, H., Zhu, M., Hu, X., Wang, J., Sun, Y., & Yang, J. (2023). Research on short-term load forecasting of new-type power system based on GCN-LSTM considering multiple influencing factors. *Energy Reports*, 9, 1022–1031. <https://doi.org/https://doi.org/10.1016/j.egy.2023.05.048>
- Chen, Y., Xu, P., Chu, Y., Li, W., Wu, Y., Ni, L., Bao, Y., & Wang, K. (2017). Short-term electrical load forecasting using the Support Vector Regression (SVR) model to calculate the demand response baseline for office buildings. *Applied Energy*, 195, 659–670. <https://doi.org/https://doi.org/10.1016/j.apenergy.2017.03.034>
- Corradini, F., Gerosa, F., Gori, M., Lucheroni, C., Piangerelli, M., & Zannotti, M. (2026). A systematic literature review of spatio-temporal graph neural network models for time series forecasting and classification. *Neural Networks*, 195, 108269. <https://doi.org/https://doi.org/10.1016/j.neunet.2025.108269>
- Criado-Ramón, D., Ruiz, L. G. B., & Pegalajar, M. C. (2022). Electric demand forecasting with neural networks and symbolic time series representations. *Applied Soft Computing*, 122, 108871. <https://doi.org/https://doi.org/10.1016/j.asoc.2022.108871>



- Erlangga, G., & Cho, S.-B. (2025). Causally explainable artificial intelligence on deep learning model for energy demand prediction. *Engineering Applications of Artificial Intelligence*, 162, 112620. <https://doi.org/https://doi.org/10.1016/j.engappai.2025.112620>
- Gao, Y., Xu, X., Yiu, T. W., & Wang, J. (2025). Transfer learning for smart construction: Advances and future directions. *Automation in Construction*, 175, 106238. <https://doi.org/https://doi.org/10.1016/j.autcon.2025.106238>
- Ghosh, S., Kumar, N., & Chattopadhyay, S. (2025). Electrically conductive “SMART” hydrogels for on-demand drug delivery. *Asian Journal of Pharmaceutical Sciences*, 20(1), 101007. <https://doi.org/https://doi.org/10.1016/j.ajps.2024.101007>
- Liu, G., Yu, J., Luo, X., Del Pero, C., Zhao, S., Huang, W., & Zhao, X. (2026). An integrated method for electric load forecasting in large public buildings based on load patterns clustering and multi-scale temporal feature selection. *Energy*, 347, 140438. <https://doi.org/https://doi.org/10.1016/j.energy.2026.140438>
- Liu, G., Zhang, C., Wang, Y., Cao, D., Zhang, X., Jing, Y., & Zhu, H. (2025). Medium- and long-term load reliability forecasting method of power system based on CNN-GRU hybrid neural network. *Results in Engineering*, 28, 108263. <https://doi.org/https://doi.org/10.1016/j.rineng.2025.108263>
- Liu, X., Zou, L., Han, Z., Jiang, J., Wang, Y., & Wang, R. (2026). A novel U-Net-physical informed neural network model for load forecasting of hydrogen power boat power system combined multi-source information spatiotemporal matrix construction. *Engineering Applications of Artificial Intelligence*, 167, 113807. <https://doi.org/https://doi.org/10.1016/j.engappai.2026.113807>
- López Santos, M., Díaz García, S., García-Santiago, X., Ogando-Martínez, A., Echevarría Camarero, F., Blázquez Gil, G., & Carrasco Ortega, P. (2023). Deep learning and transfer learning techniques applied to short-term load forecasting of data-poor buildings in local energy communities. *Energy and Buildings*, 292, 113164. <https://doi.org/https://doi.org/10.1016/j.enbuild.2023.113164>
- Mansoor, A., Liu, S., Ali, G. M., Bouferguene, A., & Al-Hussein, M. (2022). Scientometric analysis and critical review on the application of deep learning in the construction industry. *Canadian Journal of Civil Engineering*, 50(4), 253–269. <https://doi.org/https://doi.org/10.1139/cjce-2022-0379>



- Mavromatidis, G., Orehounig, K., & Carmeliet, J. (2017). Designing electrically self-sufficient distributed energy systems under energy demand and solar radiation uncertainty. *Energy Procedia*, 122, 1027–1032. <https://doi.org/https://doi.org/10.1016/j.egypro.2017.07.470>
- Miraki, A., Parviainen, P., & Arghandeh, R. (2024). Electricity demand forecasting at distribution and household levels using explainable causal graph neural network. *Energy and AI*, 16, 100368. <https://doi.org/https://doi.org/10.1016/j.egyai.2024.100368>
- Mohammad, A. A. S., Oraini, B. Al, Mohammad, S. I., Alenazi, S. A., Al-Fawwaz, T. M., & Vasudevan, A. (2026). Mathematical and statistical modelling of electricity demand forecasting using artificial neural networks and SARIMA: Implications for energy supply chain planning. *Alexandria Engineering Journal*, 139, 98–108. <https://doi.org/https://doi.org/10.1016/j.aej.2026.01.046>
- Mohammed, N. A. (2018). Modelling of unsuppressed electrical demand forecasting in Iraq for long term. *Energy*, 162, 354–363. <https://doi.org/https://doi.org/10.1016/j.energy.2018.08.030>
- Morales-Acevedo, A. (2014). Forecasting Future Energy Demand: Electrical Energy in Mexico as an Example Case. *Energy Procedia*, 57, 782–790. <https://doi.org/https://doi.org/10.1016/j.egypro.2014.10.286>
- Morteza, A., Yahyaieian, A. A., Mirzaeibonehkhater, M., Sadeghi, S., Mohaimeni, A., & Taheri, S. (2023). Deep learning hyperparameter optimization: Application to electricity and heat demand prediction for buildings. *Energy and Buildings*, 289, 113036. <https://doi.org/https://doi.org/10.1016/j.enbuild.2023.113036>
- Na, N. (2024). Research on Supply Chain Demand Prediction Model Based on LSTM. *Procedia Computer Science*, 243, 313–322. <https://doi.org/https://doi.org/10.1016/j.procs.2024.09.039>
- Panales-Pérez, A., Flores-Tlacuahuac, A., & Hernández-Romero, I. M. (2025). Prediction of electricity demand in weakly interconnected power systems using an ensemble time series model with a Bayesian Optimization approach. *Chemical Engineering Research and Design*, 220, 652–666. <https://doi.org/https://doi.org/10.1016/j.cherd.2025.07.022>
- Peng, J., Kimmig, A., Wang, J., Liu, X., Niu, Z., & Ovtcharova, J. (2021). Dual-stage attention-based long-short-term memory neural networks for energy demand



prediction. *Energy and Buildings*, 249, 111211.
<https://doi.org/https://doi.org/10.1016/j.enbuild.2021.111211>

Qin, Q., & Evins, R. (2026). Deep temporal convolutional residual neural network (ResNet)–based surrogate models for time-series load prediction and fast demand response evaluation across buildings and climates. *Energy Conversion and Management*, 354, 121278. <https://doi.org/https://doi.org/10.1016/j.enconman.2026.121278>

Ramos, D., Faria, P., & Vale, Z. (2026). Linking short-term electricity demand forecasting and explainable AI: A review for building energy applications. *Applied Energy*, 412, 127658. <https://doi.org/https://doi.org/10.1016/j.apenergy.2026.127658>

Sarker, M. A. A., Shanmugam, B., Azam, S., & Thennadil, S. (2024). Enhancing smart grid load forecasting: An attention-based deep learning model integrated with federated learning and XAI for security and interpretability. *Intelligent Systems with Applications*, 23, 200422. <https://doi.org/https://doi.org/10.1016/j.iswa.2024.200422>

Satpathy, P. R., & Ramachandaramurthy, V. K. (2026). Artificial intelligence and machine learning for distributed energy resource management systems: Applications, frameworks, and future directions. *Applied Energy*, 403, 127109. <https://doi.org/https://doi.org/10.1016/j.apenergy.2025.127109>

Serrano-Guerrero, X., Briceño-León, M., Clairand, J.-M., & Escrivá-Escrivá, G. (2021). A new interval prediction methodology for short-term electric load forecasting based on pattern recognition. *Applied Energy*, 297, 117173. <https://doi.org/https://doi.org/10.1016/j.apenergy.2021.117173>

Shaqour, A., & Hagishima, A. (2026). Residential electrical demand data synthesis using the DGAN model: performance evaluation for diverse dwellings. *Energy and Buildings*, 351, 116722. <https://doi.org/https://doi.org/10.1016/j.enbuild.2025.116722>

Shaqour, A., Ono, T., Hagishima, A., & Farzaneh, H. (2022). Electrical demand aggregation effects on the performance of deep learning-based short-term load forecasting of a residential building. *Energy and AI*, 8, 100141. <https://doi.org/https://doi.org/10.1016/j.egyai.2022.100141>

Vinayagam, A., T, S. S., Amalorpavaraj, R. A. J., Aziz, N. F. A., Mansor, M. H., C, D., & Kamwa, I. (2026). A hyperband optimized Bi-LSTM model for electric demand forecasting in diversified power systems. *Results in Engineering*, 29, 109891. <https://doi.org/https://doi.org/10.1016/j.rineng.2026.109891>



Zhang, D., Wang, S., Liang, Y., & Du, Z. (2023). A novel combined model for probabilistic load forecasting based on deep learning and improved optimizer. *Energy*, 264, 126172. <https://doi.org/https://doi.org/10.1016/j.energy.2022.126172>

Zhou, Y., Wang, J., Liu, Y., Yan, R., & Ma, Y. (2021). Incorporating deep learning of load predictions to enhance the optimal active energy management of combined cooling, heating and power system. *Energy*, 233, 121134. <https://doi.org/https://doi.org/10.1016/j.energy.2021.121134>

Conflicto de Intereses: Los autores afirman que no existen conflictos de intereses en este estudio y que se han seguido éticamente los procesos establecidos por esta revista. Además, aseguran que este trabajo no ha sido publicado parcial ni totalmente en ninguna otra revista.

CONTRIBUCIÓN DE AUTORÍA:

Nombres de autores e iniciales: Samantha Marlene Puente Bosquez (SMPB), Carlos Isaac Machuca Valverde (CIMV), Juan Carlos Pisco Vanegas (JCPV), Danner Anderson Figueroa Guerra (DAFG).

1. Conceptualización: (SMPB), (CIMV)
2. Curación de datos: (JCPV)
3. Análisis formal: (DAFG) (SMPB)
4. Adquisición de fondos: (DAFG), (CIMV)
5. Investigación: (SMPB)
6. Metodología: (JCPV), (CIMV)
7. Administración del proyecto: (SMPB)
8. Recursos: (DAFG)
9. Software: (CIMV)
10. Supervisión: (SMPB)
11. Validación: (SMPB), (DAFG)
12. Visualización: (JCPV)
13. Redacción -- Borrador original: (SMPB)
14. Redacción -- Revisión y edición: (DAFG)

