

Implementación de un modelo híbrido CNN-LSTM con HGB para pronóstico de demanda eléctrica de corto plazo en una distribuidora local

Implementation of hybrid CNN-LSTM with HGB model for short-term load forecasting in local distribution utility

Doctorando:

Mariano MUJICA

Observatorio de Energía y Sustentabilidad, Departamento de Ingeniería en Energía Eléctrica, Facultad Regional Rosario, Universidad Tecnológica Nacional – Argentina

mmujica@frr.utn.edu.ar

<https://orcid.org/0009-0004-7674-0424>

Director:

Pablo RULLO

Observatorio de Energía y Sustentabilidad, Departamento de Ingeniería en Energía Eléctrica, Facultad Regional Rosario, Universidad Tecnológica Nacional – Argentina

pablogrullo@gmail.com

<https://orcid.org/0000-0001-9003-1000>

Codirector:

Lautaro BRACCIA

Grupo de Investigación en Aplicaciones de la Ingeniería de Procesos, Facultad Regional Rosario, Universidad Tecnológica Nacional – Argentina

lautaro.braccia.LB@gmail.com

<https://orcid.org/0000-0003-1651-5386>

Resumen

El pronóstico de demanda eléctrica de corto plazo aporta información anticipada para la operación, la compra de energía y la evaluación de restricciones en redes de distribución. Se desarrolla y evalúa una metodología híbrida para la Cooperativa de Energía y Consumos de Ibarlucea, Santa Fe, a partir de mediciones reales de potencia activa cada 15 minutos, registradas entre julio de 2024 y abril de 2026 en el punto de interconexión con la red aguas arriba, datos meteorológicos de la estación meteorológica del aeropuerto de Rosario y descriptores temporales. El pronóstico multihorizonte combina una arquitectura CNN-LSTM sequence-to-sequence con un modelo Histogram Gradient Boosting que estima los residuos del predictor inicial. Se evaluaron resoluciones horaria y de 15 minutos, horizontes de uno a tres días y ventanas históricas de dos, cuatro y siete días. Para una ventana de dos días y un horizonte de un día, la configuración de 15 minutos redujo el MAE de 64,46 a 51,83 kW y el RMSE de 102,57 a 94,33 kW; el MAE en picos disminuyó de 102,29 a 83,79 kW. En general, la corrección residual mejoró la precisión global y en alta demanda, aunque persiste un sesgo de subestimación. La mayor granularidad temporal resultó ventajosa, mientras que ampliar la ventana histórica no produjo mejoras sistemáticas.

Palabras clave: Pronóstico de demanda de corto plazo; redes de distribución; redes neuronales; aprendizaje automático; corrección residual; cooperativas eléctricas.

Abstract

Short-term electricity load forecasting provides anticipatory information for operation, energy procurement, and network-constraint assessment in distribution systems. This work develops and evaluates a hybrid methodology for the Ibarlucea Energy and Consumption Cooperative in Santa Fe, Argentina, using real active-power measurements recorded every 15 minutes from July 2024 to April 2026 at the point of interconnection with the upstream grid, meteorological data from Rosario Airport station, and temporal descriptors. The multi-horizon forecast combines a CNN-LSTM sequence-to-sequence architecture with a Histogram Gradient Boosting model that estimates the neural predictor residuals. Hourly and 15-minute resolutions, one- to three-day horizons, and two-, four-, and seven-day historical windows were evaluated. For a two-day window and a one-day horizon, the 15-minute configuration reduced MAE from 64.46 to 51.83 kW and RMSE from 102.57 to 94.33 kW; peak MAE decreased from 102.29 to 83.79 kW. Overall, residual correction improved both global and high-

demand accuracy, although an underestimation bias remained. Finer temporal granularity was advantageous, whereas extending the historical window did not produce systematic improvements.

Keywords: Short-term load forecasting; distribution networks; neural networks; machine learning; residual correction; electric cooperatives.

Introducción

La digitalización de las redes de distribución, la incorporación de medición avanzada y el crecimiento de los recursos energéticos distribuidos aumentan la necesidad de herramientas predictivas para asistir la operación. El pronóstico de demanda de corto plazo permite anticipar máximos, evaluar restricciones, programar compras y aportar información a sistemas avanzados de gestión de distribución (Saviozzi et al., 2019). Su aplicación en distribuidoras locales es exigente: la menor agregación vuelve a las series más variables y sensibles a condiciones meteorológicas, calendarias y eventos atípicos (Pinheiro et al., 2023).

Los datos de medidores y dispositivos de campo habilitan aplicaciones de pronóstico, diagnóstico y soporte a la planificación (Athanasiadis et al., 2024). Las redes neuronales recurrentes permiten representar dependencias temporales multivariadas (Uhrig et al., 2026), mientras que las redes convolucionales extraen patrones locales de la forma de carga. Las arquitecturas encoder-decoder resultan adecuadas para generar trayectorias completas de pronóstico y combinar información exógena (Jurado et al., 2023). Sin embargo, su uso operativo requiere robustez y trazabilidad, en línea con los desafíos generales de la inteligencia artificial en sistemas eléctricos (Bessa et al., 2026).

Este trabajo, integrado a la línea de analítica de datos del plan doctoral, tiene como objetivo desarrollar y evaluar una metodología híbrida para el pronóstico multihorizonte de potencia activa en una distribuidora local. La contribución consiste en implementar una arquitectura que combine *Convolutional Neural Networks* (CNN) y *Long-Short Term Memory Recurrent Neural Networks* (LSTM) *sequence-to-sequence* con un corrector residual basado en *Histogram Gradient Boosting Decision Tree* (HGB), y analizar su desempeño con datos operativos reales de la Cooperativa de Energía y Consumos de Ibarlucea. Se estudia la influencia de la resolución temporal, el horizonte y la longitud de la ventana histórica, con énfasis en los períodos de máxima demanda.

Caso de estudio y conjunto de datos

La red de la Cooperativa de Energía y Consumos de Ibarlucea se conecta a su proveedor aguas arriba mediante un único punto de interconexión. La serie eléctrica comprende registros entre julio de 2024 y abril de 2026 con intervalo de 15 minutos. Aunque los archivos incluyen potencia activa y energías activa y reactiva, el objetivo de pronóstico se restringió a la potencia activa agregada. Para la configuración horaria se promediaron las cuatro muestras de cada hora.

Se incorporaron observaciones horarias de temperatura, humedad relativa y presión atmosférica de la estación Servicio Meteorológico Nacional localizada en el aeropuerto de Rosario. Para trabajar a 15 minutos se aplicó interpolación lineal. También se generaron descriptores de hora, día de la semana, mes, día del año, minuto y feriados, con codificaciones cíclicas. Las mediciones meteorológicas observadas se utilizaron como sustituto controlado de pronósticos futuros; por ello, los resultados no representan todavía la incertidumbre meteorológica de una implementación operacional.

Los valores anómalos de potencia se limitaron mediante un filtro estadístico móvil con umbral de dos desvíos estándar locales. A las variables de entrada se les aplicó una normalización Min-Max, mientras que la variable objetivo estandarizó utilizando la media y el desvío estándar calculados exclusivamente con el conjunto de entrenamiento. Los pares se dividieron cronológicamente en 56 % para entrenamiento, 14 % para validación y 30 % final para prueba, evitando fuga de información temporal.

Metodología de pronóstico

La primera etapa recibe una secuencia histórica multivariada y una secuencia de variables conocidas sobre el horizonte. Tres ramas de CNN paralelas, con 32 filtros y kernels que abarquen 6, 12 y 24 horas, extraen patrones locales; sus salidas

alimentan un codificador LSTM. Un segundo LSTM procesa las variables futuras y el decodificador genera simultáneamente la trayectoria completa de potencia. Esta formulación evita entrenar un modelo independiente para cada paso y conserva la coherencia temporal del pronóstico.

Las variables de entrada a las ramas convolucionales incluyen los valores de consumo de potencia activa, energía activa y reactiva normalizados, los valores de variables meteorológicas históricas de temperatura ambiente, humedad relativa ambiente y presión atmosférica, junto con los descriptores temporales y del calendario. En paralelo ingresan a una LSTM las variables meteorológicas del horizonte de predicción, consideradas como pronóstico meteorológico.

En la segunda etapa, un regresor HGB aprende los errores sistemáticos del predictor base a partir de variables eléctricas, meteorológicas y calendarias. El esquema se resume como:

$$\text{pronóstico final} = \text{pronóstico base} + \text{residuo estimado}$$

La corrección residual es una estrategia coherente con enfoques híbridos reportados para pronóstico de carga (Nguyen & Ha, 2025). El modelo completo se entrenó con optimizador Adam que ajusta la tasa de aprendizaje para evitar los mínimos locales y las grandes oscilaciones. Se implementó la pérdida Huber como función a minimizar, ya que permite equilibrar las penalizaciones tanto en errores grandes como errores pequeños sistemáticos. Además, se entrenó con detención temprana para evitar sobreajuste; el corrector HGB se ajustó con el error absoluto como función pérdida y 150 iteraciones máximas.




Figura 1. Arquitectura CNN-LSTM sequence-to-sequence y corrector residual basado en HGB.

Configuración experimental

Se analizaron 18 combinaciones: horizontes (H) de uno, dos y tres días; ventanas históricas de dos, cuatro y siete días y resoluciones de una hora y 15 minutos. Se generaron orígenes de pronóstico consecutivos con desplazamiento de un paso de muestreo. La evaluación incluyó MAE, RMSE. Para estudiar la capacidad de capturar los picos de demanda se calculó además el MAE y el sesgo sobre muestras cuya demanda medida superó el percentil 90; un sesgo negativo indica subestimación.

Resultados y discusión

La corrección residual redujo el MAE y el RMSE globales en casi todos los escenarios representativos. La excepción fue la configuración de 15 minutos, ventana de cuatro días y horizonte de un día, donde el MAE pasó de 56,76 a 56,86 kW, una diferencia despreciable, mientras que el RMSE y los indicadores de pico mejoraron.

Con ventana de dos días y horizonte de un día, el corrector redujo el MAE horario de 69,41 a 58,46 kW y el de 15 minutos de 64,46 a 51,83 kW. Al extender el horizonte a tres días, la ventaja de la mayor granularidad se volvió más marcada: el modelo corregido alcanzó 60,10 kW de MAE a 15 minutos frente a 76,80 kW en la resolución horaria. El error creció con el horizonte, como resulta esperable por la menor información disponible a medida que aumenta la distancia al origen.

El MAE de pico disminuyó después de la corrección en todos los casos presentados. No obstante, el sesgo permaneció negativo indicando que el modelo subestima de manera sistemática los picos de consumo. La Figura 2 ilustra como el corrector mejora la predicción general y en períodos de alta carga, captando el horario del pico con alta precisión, pero no es capaz de reproducir por completo la potencia consumida en picos abruptos.

La Tabla 1, para facilitar la interpretación, muestra los resultados obtenidos para los modelos generados con horizontes de uno y tres días y ventanas de dos y cuatro días.

H	Ventana	Resolución	Modelo	MAE	RMSE	MAE pico	Sesgo pico
1 día	2 días	1 h	Base	69,41	104,98	115,63	-108,10
1 día	2 días	1 h	Corregido	58,46	97,71	93,41	-76,48
1 día	2 días	15 min	Base	64,46	102,57	102,29	-89,94
1 día	2 días	15 min	Corregido	51,83	94,33	83,79	-58,08
1 día	4 días	1 h	Base	67.48	104.95	117.17	-110.28
1 día	4 días	1 h	Corregido	58.58	98.83	90.60	75.30
1 día	4 días	15 min	Base	56.76	101.18	96.27	-77.09
1 día	4 días	15 min	Corregido	56.86	100.71	82.32	59.04
3 días	2 días	1 h	Base	82.85	126.25	170.99	-164.11
3 días	2 días	1 h	Corregido	76.80	121.64	152.92	-141.02
3 días	2 días	15 min	Base	79.31	116.21	12.34	-116.67
3 días	2 días	15 min	Corregido	60.10	103.61	90.80	-67.68
3 días	4 días	1 h	Base	81.81	126.69	171.76	-168.53
3 días	4 días	1 h	Corregido	72.36	118.65	143.28	-134.31
3 días	4 días	15 min	Base	73.97	115.83	148.67	-139.36
3 días	4 días	15 min	Corregido	67.70	110.75	129.18	-115.44

Tabla 1. Desempeño representativo para una ventana histórica de dos días. Todos los errores se expresan en kW; los indicadores de pico se calculan por encima del percentil 90 de la demanda medida.

Las ventanas de cuatro días fueron competitivas en algunas configuraciones, pero no mejoraron de forma sistemática a las de dos días. Las ventanas de siete días, tampoco produjeron una ganancia consistente. Esto sugiere que, para la arquitectura y el caso estudiados, la información más reciente de demanda, calendario y meteorología contiene la mayor parte de la señal útil, y que una historia más extensa puede agregar redundancia sin compensar la mayor complejidad.




Figura 2. Casos representativos con resolución de 15 minutos, ventana histórica de dos días y horizonte de un día: buen seguimiento de picos (izquierda) y subestimación persistente de máximos abruptos (derecha).

Conclusiones

Se desarrolló una metodología híbrida para pronosticar la demanda de potencia activa de una cooperativa eléctrica a partir de datos operativos reales. La etapa con el modelo HGB corrigió componentes residuales del predictor CNN-LSTM sequence-to-sequence y mejoró la precisión global y durante alta demanda en la mayoría de los escenarios. La resolución de 15 minutos superó en general a la horaria y las ventanas compactas ofrecieron resultados competitivos.

La subestimación de los máximos no fue eliminada y constituye la principal limitación. También debe considerarse que se utilizaron observaciones meteorológicas como sustituto de pronósticos futuros. Las próximas etapas del trabajo doctoral incorporarán optimización de hiperparámetros, selección sistemática de variables, funciones de pérdida orientadas a picos, pronóstico probabilístico y predicciones meteorológicas reales, con el objetivo de avanzar hacia una herramienta operativa para distribuidoras locales.

Utilización de IA generativa / herramientas IA

Declaro la utilización de la herramienta de inteligencia artificial generativa ChatGPT, mediante GPT Work de OpenAI, para asistir en la traducción, síntesis, reorganización del manuscrito, revisión de redacción y adecuación al formato editorial de las Jornadas. La herramienta no fue utilizada para generar nuevos datos experimentales ni modificar los resultados obtenidos. Confirmando que, luego de su utilización, los contenidos fueron revisados, constatados y editados por los autores, quienes asumen plena responsabilidad por el contenido presentado.

Referencias

- Athanasiadis, C. L., Papadopoulos, T. A., Kryonidis, G. C., & Doukas, D. I. (2024). A review of distribution network applications based on smart meter data analytics. *Renewable and Sustainable Energy Reviews*, 191, 114151. <https://doi.org/10.1016/j.rser.2023.114151>
- Bessa, R. J., Chatzivasileiadis, S., Zhang, N., Kang, C., & Hatziargyriou, N. (2026). Current and future applications of artificial intelligence in power systems: A critical appraisal. *Journal of Modern Power Systems and Clean Energy*, 14(1), 23–36. <https://doi.org/10.35833/MPCE.2025.000990>
- Jurado, M., Samper, M., & Rosés, R. (2023). An improved encoder-decoder-based CNN model for probabilistic short-term load and PV forecasting. *Electric Power Systems Research*, 217, 109153. <https://doi.org/10.1016/j.eprsr.2023.109153>
- Nguyen, T. A., & Ha, C. K. (2025). A residual error correction hybrid CNN-LightGBM model for accurate short-term electric load forecasting. *Journal of Robotics and Control*, 6(6), 2666–2675. <https://doi.org/10.18196/jrc.v6i6.28482>
- Pinheiro, M. G., Madeira, S. C., & Francisco, A. P. (2023). Short-term electricity load forecasting: A systematic approach from system level to secondary substations. *Applied Energy*, 332, 120493. <https://doi.org/10.1016/j.apenergy.2022.120493>

Saviozzi, M., Massucco, S., & Silvestro, F. (2019). Implementation of advanced functionalities for distribution management systems: Load forecasting and modeling through artificial neural networks ensembles. *Electric Power Systems Research*, 167, 230–239. <https://doi.org/10.1016/j.epsr.2018.10.036>

Servicio Meteorológico Nacional. (2026). *Descarga de datos*. Recuperado el 16 de junio de 2026, de <https://ws2.smn.gob.ar/descarga-de-datos>

Uhrig, M. N., Vignolo, L. D., & Müller, O. V. (2026). Multivariate forecasting of energy demand using recurrent neural networks. *Advanced Engineering Informatics*, 71, 104419. <https://doi.org/10.1016/j.aei.2026.104419>