



Doi: <https://doi.org/10.70577/ASCE/240.260/2025>

Recibido: 2025-05-09

Aceptado: 2025-06-09

Publicado: 2025-07-10

Limitaciones del Modelo LSTM en la Predicción de Demanda Eléctrica con Datos Simulados de Bajo Volumen

Limitations of the LSTM Model in Electricity Demand Forecasting with Low Volume Simulated Data

Autores

Christian Paul Reyes Orozco

cpreyes@esPOCH.edu.ec

<https://orcid.org/0009-0002-8254-4564>

Escuela Superior Politécnica de Chimborazo (ESPOCH)

Cristian Luis Inca Balseca

cristianl.inca@esPOCH.edu.ec

<https://orcid.org/0000-0002-4795-8297>

Escuela Superior Politécnica de Chimborazo (ESPOCH)

Cómo citar

Reyes Orozco, C. P., & Inca Balseca, C. L. (2025). Limitaciones del Modelo LSTM en la Predicción de Demanda Eléctrica con Datos Simulados de Bajo Volumen. *ASCE*, 4(3), 240–260.



Resumen

El análisis evaluó el modelo LSTM para predecir la demanda eléctrica, utilizando un conjunto simulado de 1000 puntos (42 días) con variables como temperatura, radiación solar y tipo de consumidor (residencial/industrial). Los resultados muestran un desempeño deficiente, con valores negativos de R^2 (-0.0043, -0.1380, -0.0849) y RMSE elevados (29.23, 31.68, 30.52), indicando predicciones menos precisas que el promedio de los datos. La configuración del modelo (50 neuronas, look_back=24) resultó inestable, probablemente debido al tamaño limitado del conjunto de datos y a la incapacidad para capturar relaciones entre las variables y la demanda eléctrica. La literatura destaca que los modelos LSTM requieren grandes volúmenes de datos y una optimización cuidadosa para ser efectivos. Comparado con ARIMA, un método estadístico tradicional, el LSTM no logró capturar patrones temporales complejos. Los desafíos incluyen la calidad de los datos, la complejidad del modelo y la integración con sistemas heredados. Se sugiere aumentar el tamaño del conjunto de datos, ajustar la arquitectura del modelo y explorar enfoques híbridos (LSTM+ARIMA) para mejorar la precisión. Este análisis resalta la importancia de alinear la complejidad del modelo con los datos disponibles para optimizar la gestión energética en redes inteligentes.

Palabras clave: Demanda Eléctrica, LSTM, ARIMA, Aprendizaje Automático.



Abstract

The analysis evaluated the LSTM model to predict electricity demand, using a simulated set of 1000 points (42 days) with variables such as temperature, solar radiation and type of consumer (residential/industrial). The results show poor performance, with negative R^2 values (-0.0043, -0.1380, -0.0849) and high RMSE (29.23, 31.68, 30.52), indicating less accurate predictions than the average data. The model configuration (50 neurons, look_back=24) proved unstable, probably due to the limited size of the data set and the inability to capture relationships between variables and electrical demand. The literature highlights that LSTM models require large data volumes and careful optimization to be effective. Compared to ARIMA, a traditional statistical method, LSTM failed to capture complex temporal patterns. Challenges include data quality, model complexity, and integration with legacy systems. It is suggested to increase the size of the data set, adjust the model architecture and explore hybrid approaches (LSTM+ARIMA) to improve accuracy. This analysis highlights the importance of aligning model complexity with available data to optimize energy management in smart grids.

Keywords: Electricity demand, LSTM, ARIMA, machine learning.

Introducción

La previsión de la demanda de electricidad es crucial para una gestión eficaz de los recursos en la generación, distribución y consumo de energía, especialmente en el contexto de las redes inteligentes en evolución. A medida que el consumo global de electricidad aumenta, las predicciones precisas de la demanda se vuelven esenciales para garantizar la fiabilidad del sistema y mitigar las escaseces, lo que convierte el desarrollo de metodologías avanzadas de pronóstico en un área de investigación significativa, (Amat R., 2023), (Ugbehe, Diemuodeke & Aikhuele, 2025).

Los recientes avances en el aprendizaje automático (ML) han demostrado resultados prometedores en la mejora de la precisión de las predicciones, abordando la compleja interacción de variables como el clima, las condiciones económicas y el comportamiento humano que influyen en el uso de la electricidad, (Duan, Chen & Waang, 2025).

Los modelos de aprendizaje automático, incluidas las redes de Memoria a Largo y Corto Plazo (LSTM) y los enfoques híbridos de pronóstico, han surgido como herramientas clave en este campo. Estos modelos aprovechan grandes cantidades de datos de series temporales para identificar patrones y tendencias complejas que los métodos estadísticos tradicionales pueden pasar por alto, (Ibrahim, Rabelo, Gutierrez & Clavijo, 2022)

Los estudios indican que las técnicas de pronóstico basadas en ML a menudo superan a los modelos convencionales, reduciendo significativamente los errores de predicción y mejorando la eficiencia de los sistemas de gestión de energía, (Dahya, 2023).

Este cambio hacia el ML refleja la creciente complejidad de los entornos de redes inteligentes, donde la adaptabilidad y precisión en tiempo real son fundamentales para mantener la resiliencia operativa.

Sin embargo, la integración del aprendizaje automático en la previsión de la demanda de electricidad no está exenta de desafíos. Los problemas relacionados con la calidad y disponibilidad de los datos, la transparencia del modelo y la integración de los sistemas de ML



con infraestructuras heredadas plantean barreras significativas para la adopción generalizada (Hussian, Ching & Noor, 2025).

Además, la naturaleza de "caja negra" de muchos algoritmos de ML plantea preocupaciones sobre la confianza y la interpretabilidad, particularmente entre los interesados que dependen de estas predicciones para la toma de decisiones críticas, (Allal, Noura, Salaman, 2024).

Abordar estos desafíos será esencial para avanzar en el papel del aprendizaje automático en los sistemas energéticos y asegurar su efectividad en la promoción del uso sostenible de la electricidad. A medida que avanza la investigación, el potencial del aprendizaje automático para transformar la previsión de la demanda de electricidad sigue creciendo, ofreciendo caminos para mejorar la precisión y la eficiencia operativa. Los desarrollos futuros probablemente se centren en la optimización de algoritmos, la mejora de las estrategias de integración de datos y la atención a las consideraciones éticas, contribuyendo en última instancia a la descarbonización de los sistemas energéticos y apoyando los objetivos globales de neutralidad de carbono para 2050, (jain & Gupta, 2024).

La previsión de la demanda de electricidad desempeña un papel crucial en la gestión y planificación de los recursos para la generación, distribución y utilización de la energía. A medida que el consumo de electricidad sigue aumentando, predecir la demanda con precisión es esencial para garantizar una gestión eficiente de la cadena de suministro y mitigar posibles escaseces, (Amat & Escobar, 2023).

La complejidad de la previsión está influenciada por varios factores, incluidos los patrones climáticos, las condiciones económicas y el comportamiento social, lo que hace imperativo el desarrollo de modelos predictivos robustos, (Amat & Escobar, 2023).

Importancia de la Predicción de la Demanda de Electricidad

La electricidad es una necesidad fundamental tanto para las actividades domésticas como industriales, con un consumo industrial en los países en desarrollo que se estima representa entre

el 45% y el 50% del uso comercial total, (Ugbehe, Diemuodeke, Selivano, Muraviev & Shakhnov, 2023).

La creciente dependencia de la energía eléctrica está impulsando un aumento progresivo en la demanda, lo que requiere metodologías de pronóstico efectivas para gestionar este crecimiento de manera sostenible. La capacidad de prever las tendencias de series temporales no solo ayuda en la planificación de recursos, sino que también contribuye a evitar escenarios indeseados relacionados con la escasez de suministros y los precios fluctuantes. (Ugbehe, Diemuodeke, Selivano, Muraviev & Shakhnov, 2023).

Metodologías para Predecir la Demanda de Electricidad

Existen diversas metodologías para pronosticar la demanda de electricidad, incluyendo modelos estadísticos tradicionales como el Promedio Móvil Integrado Autorregresivo (ARIMA) y técnicas de aprendizaje automático que utilizan datos de series temporales. El análisis de series temporales examina los datos de uso históricos para identificar tendencias y patrones estacionales, proporcionando información para futuras predicciones, (Amat & Escobar, 2023).

Los modelos de aprendizaje automático, incluidos las redes de memoria a largo y corto plazo (LSTM) y los árboles de decisión, mejoran la precisión de las previsiones al considerar múltiples variables exógenas, como la temperatura y los patrones de consumo pasados, (Duan, Xu, Chen & Wang, 2025).

En estudios recientes, el desarrollo de marcos de aprendizaje automático ha demostrado una mayor precisión en la predicción de la demanda de electricidad en comparación con los métodos tradicionales. En estudios recientes, el desarrollo de marcos de aprendizaje automático ha demostrado una mayor precisión en la predicción de la demanda de electricidad en comparación con los métodos tradicionales, (Dahya, 2023)

Estos modelos avanzados pueden procesar grandes cantidades de datos, capturando interacciones y tendencias complejas que pueden no ser evidentes a través de enfoques más simples.

El cambio hacia técnicas de aprendizaje automático refleja la creciente necesidad de herramientas de pronóstico más adaptables y confiables en el contexto de las redes inteligentes, donde los ajustes en tiempo real son críticos para mantener la resiliencia y eficiencia del sistema.

Desafíos en la Predicción de la Demanda de Electricidad

A pesar de los avances en las metodologías de pronóstico, persisten desafíos, particularmente en lograr la transparencia e interpretabilidad de los modelos. Muchos algoritmos de aprendizaje automático funcionan como "cajas negras," lo que dificulta que las partes interesadas comprendan el proceso de toma de decisiones.

A medida que la integración del aprendizaje automático en los sistemas de gestión de energía aumente, es probable que el enfoque se desplace hacia el desarrollo de modelos que no solo mejoren las capacidades predictivas, sino que también proporcionen claridad sobre sus mecanismos operativos, fomentando así la confianza y seguridad de los interesados en estos sistemas.

Materiales y Métodos

Modelos de Aprendizaje Automático

Los modelos de aprendizaje automático (ML) han surgido como herramientas poderosas en la previsión de la demanda eléctrica dentro de las redes inteligentes. Estos modelos aprovechan algoritmos avanzados para mejorar la precisión de las predicciones, particularmente en escenarios caracterizados por patrones de datos complejos y no lineales, que a menudo están presentes en las métricas de consumo eléctrico.

Resumen de Técnicas de Aprendizaje Automático

Las técnicas de ML generalmente se categorizan en aprendizaje supervisado, no supervisado y por refuerzo. El aprendizaje supervisado se basa en conjuntos de datos etiquetados para entrenar modelos que pueden predecir resultados para nuevos datos no etiquetados. En contraste, el aprendizaje no supervisado se centra en identificar patrones ocultos y relaciones dentro de los

datos que no tienen etiquetas históricas. Esta capacidad es particularmente útil para comprender las complejas relaciones que influyen en la demanda eléctrica.

Modelos Híbridos de Pronóstico

Un avance significativo en el ML para la previsión de la demanda eléctrica es el desarrollo de modelos de previsión híbridos. Estos modelos integran métodos estadísticos tradicionales con técnicas modernas de aprendizaje automático, optimizando las fortalezas de ambos enfoques. Al utilizar diversas técnicas de modelado, incluyendo regresión, análisis de series temporales y metodologías de inteligencia artificial (IA), los modelos híbridos pueden tener en cuenta tanto las características lineales como no lineales de los datos. [6][22]. La investigación indica que estos modelos híbridos frecuentemente superan a los métodos de pronóstico individuales, proporcionando una mejor precisión en métricas de predicción como el Error Cuadrático Medio (RMSE) y el Error Porcentual Absoluto Medio (MAPE).

Algoritmos Comunes

Entre los algoritmos más efectivos utilizados en ML para la predicción de la demanda eléctrica se encuentran las máquinas de gradiente boosting, las máquinas de soporte vectorial (SVM) y las redes de aprendizaje profundo. El gradient boosting construye secuencialmente un modelo de conjunto refinando iterativamente los árboles de decisión para minimizar las funciones de pérdida, mientras que el SVM busca encontrar un hiperplano óptimo que maximice el margen entre diferentes puntos de datos. Además, los modelos de conjunto que combinan múltiples técnicas de aprendizaje automático han demostrado mejorar significativamente el rendimiento de las predicciones.

Calidad y Disponibilidad de los Datos

Uno de los principales obstáculos para utilizar ML en aplicaciones de redes inteligentes es la calidad y disponibilidad de los datos. Los grandes volúmenes de datos generados por sensores y medidores inteligentes son a menudo inconsistentes, ruidosos o incompletos, lo que puede afectar gravemente el rendimiento de los algoritmos de ML.



Los conjuntos de datos de alta calidad y estandarizados son cruciales para entrenar modelos precisos; sin embargo, la escasez de dichos datos—especialmente los datos históricos—plantea dificultades significativas para el entrenamiento y la validación de modelos.

Además, la integración de datos de múltiples fuentes puede llevar a complicaciones como desajustes en los esquemas y información redundante, lo que requiere estrategias rigurosas de limpieza y preprocesamiento de datos para mantener una alta calidad de los mismos.

Escalabilidad y Procesamiento en Tiempo Real

Las redes inteligentes operan en entornos dinámicos donde las condiciones pueden cambiar rápidamente, lo que requiere capacidades de toma de decisiones en tiempo real por parte de los modelos de ML. Sin embargo, los enfoques tradicionales de ML a menudo tienen dificultades con la escalabilidad, especialmente cuando se les encarga procesar los grandes volúmenes de datos generados por las operaciones de la red.

Esto puede llevar a retrasos en los procesos de toma de decisiones si los modelos no pueden operar de manera eficiente bajo tales restricciones. Además, la potencia de cálculo requerida para el procesamiento en tiempo real puede necesitar inversiones significativas en infraestructura, lo que puede ser una barrera para la implementación.

Integración con sistemas heredados

Integrar soluciones de ML en las infraestructuras existentes de redes inteligentes es otro desafío considerable, especialmente dado que muchos sistemas implican una mezcla de tecnologías nuevas y heredadas. Las herramientas modernas de ML pueden no ser compatibles con los sistemas más antiguos, lo que puede provocar interrupciones operativas y requerir costosas actualizaciones o reemplazos.

Este desafío de integración se complica por la complejidad de coordinar entre varios interesados y asegurar la compatibilidad entre diferentes tecnologías y formatos de datos.

Confianza y Explicabilidad

Dado que los modelos de ML a menudo operan como "cajas negras," surgen problemas de confianza y explicabilidad, particularmente en contextos críticos para la seguridad como la gestión de energía. Los operadores requieren una comprensión clara y la interpretabilidad de las predicciones de los modelos para generar confianza y facilitar las intervenciones necesarias en escenarios de alto riesgo. Desarrollar métodos de IA explicable (XAI) adaptados para aplicaciones energéticas es esencial para fomentar el cumplimiento normativo y la confianza del usuario, pero sigue siendo un problema no resuelto en el campo.

Desafíos Regulatorios y de Estandarización

La falta de estandarización en los procesos de entrenamiento y prueba de modelos de ML impone limitaciones adicionales a la reproducibilidad y escalabilidad.

Las prácticas fragmentadas de gestión de datos y los marcos regulatorios inadecuados también contribuyen a los desafíos que enfrentan las implementaciones de ML en los sistemas energéticos. Establecer esquemas de datos estandarizados y entornos de evaluación abiertos es crucial para promover prácticas consistentes en todo el sector, lo que apoyaría un desarrollo y despliegue de modelos más robustos.

2.1 Modelos Estadísticos

Para predecir la demanda eléctrica, este análisis emplea dos enfoques estadísticos complementarios: las redes neuronales de memoria a corto y largo plazo (LSTM) y el modelo autorregresivo integrado de media móvil (ARIMA). A continuación, se detalla de manera clara y humana cómo se aplican estos métodos, con un enfoque en su implementación práctica y sus beneficios.

El modelo LSTM, basado en redes neuronales recurrentes, está diseñado específicamente para analizar series temporales, como la demanda eléctrica, que evoluciona con el tiempo. Este método destaca por su capacidad para "recordar" patrones a largo plazo, gracias a su estructura de puertas de entrada, olvido y salida, que gestionan de manera inteligente la información relevante. La arquitectura utilizada incluye

una capa LSTM con 50 neuronas, una capa de abandono (Dropout) del 20% para prevenir el sobreajuste y una capa densa final que genera las predicciones. Para optimizar el modelo, se configuraron hiperparámetros clave: un horizonte de 24 horas para considerar datos históricos, 50 iteraciones de entrenamiento (epochs) y un tamaño de lote de 32. Este enfoque moderno permite capturar relaciones complejas en los datos, adaptándose a patrones no lineales.

Por otro lado, el modelo ARIMA, un método estadístico clásico, ofrece una perspectiva más tradicional pero igualmente robusta. ARIMA combina tres componentes fundamentales: un término autorregresivo (AR) que modela la dependencia de valores pasados, una diferenciación (I) para estabilizar la serie temporal y un componente de media móvil (MA) que considera los errores históricos. En este análisis, se seleccionó una configuración con un orden de (5,1,0), lo que implica cinco rezagos autorregresivos, una diferenciación de primer orden y la ausencia de un componente de media móvil. Esta elección permite un enfoque más simple, pero efectivo, para capturar tendencias y patrones en la demanda eléctrica.

Antes de aplicar ambos modelos, los datos se prepararon cuidadosamente. Se utilizó un escalado MinMaxScaler para normalizar los valores entre 0 y 1, garantizando que los modelos trabajen con datos consistentes. Los valores faltantes se manejaron mediante el método de rellenado hacia adelante (forward fill), asegurando continuidad en la serie temporal. Además, se incorporaron variables externas relevantes, como la temperatura, la radiación solar y el tipo de consumidor (residencial o industrial), que enriquecen las predicciones al reflejar factores que influyen en la demanda.

Para evaluar los modelos de manera rigurosa, se empleó una validación cruzada adaptada a series temporales (TimeSeriesSplit con tres particiones), asegurando que los datos de prueba siempre fueran posteriores a los de entrenamiento, respetando la naturaleza secuencial del problema. Las métricas utilizadas incluyeron el coeficiente de determinación (R^2), que mide qué tan bien los modelos explican la variabilidad de los datos, y el error cuadrático medio (RMSE), que evalúa la precisión de las predicciones. Además, se generaron gráficos comparativos entre las predicciones y los valores reales, ofreciendo una visualización clara del desempeño de cada enfoque.

Este análisis combina la potencia de un método moderno como LSTM, ideal para capturar patrones complejos, con la solidez de un enfoque tradicional como ARIMA, que brilla en series con tendencias claras. Al integrar ambos, se logra una evaluación integral que no solo mejora la precisión de las predicciones, sino que también ofrece una comprensión más profunda de los factores que impulsan la demanda eléctrica. Este enfoque dual es especialmente valioso para quienes buscan tomar decisiones informadas en la gestión energética, adaptándose a las necesidades de un sector en constante evolución.

2.2 Datos utilizados

Para realizar este análisis, se empleó un conjunto de datos cuidadosamente diseñado para estudiar la demanda eléctrica, considerando factores clave que influyen en su comportamiento. A continuación, se describe de manera clara y accesible la estructura, las características y el procesamiento de los datos utilizados, con un enfoque profesional pero cercano.

El conjunto de datos incluye varias variables de entrada que reflejan aspectos relevantes para la predicción de la demanda eléctrica. Entre ellas, se encuentra la temperatura, medida en grados Celsius, que captura las condiciones climáticas que pueden afectar el consumo energético, como días cálidos que incrementan el uso de aire acondicionado. También se consideró la radiación solar, expresada en unidades de radiación, que refleja la influencia de la luz solar en la generación y el consumo de energía. Además, se incluyó el tipo de consumidor, clasificado en dos categorías: residencial e industrial. Esta distinción permite analizar las diferencias en los patrones de consumo según el perfil del usuario, ya que los hogares y las industrias tienen necesidades energéticas distintas. La variable de salida, o variable dependiente, es la demanda eléctrica, que representa la cantidad de electricidad consumida en un momento dado.

Los datos tienen una estructura temporal bien definida, con registros recopilados cada hora, lo que proporciona una resolución detallada para capturar fluctuaciones a lo largo del día. El período cubierto comienza el 1 de enero de 2023 y abarca un total de 1000 observaciones, equivalentes a aproximadamente 42 días de datos. Esta serie temporal continua permite analizar tendencias y patrones estacionales en la demanda eléctrica.

Es importante destacar que los datos utilizados son simulados, creados específicamente para este análisis, pero diseñados para reflejar de manera realista cómo factores como el clima y el tipo de consumidor pueden influir en el consumo eléctrico. Esta simulación asegura que los datos sean representativos de escenarios reales, incluyendo variables climáticas (temperatura y radiación solar) y categóricas (tipo de consumidor), lo que enriquece el análisis al considerar múltiples dimensiones que afectan la demanda.

Para preparar los datos y garantizar su calidad, se aplicaron varias técnicas de procesamiento. En primer lugar, se utilizó el método `MinMaxScaler` para escalar los valores numéricos entre 0 y 1, asegurando que todas las variables estén en una escala comparable y facilitando el trabajo de los modelos predictivos. Los valores faltantes, si los hubiera, se manejaron mediante el método de rellenado hacia adelante (`forward fill`), que preserva la continuidad de la serie temporal al asignar el último valor disponible a los datos ausentes. Finalmente, para evaluar los modelos de manera robusta, los datos se dividieron en conjuntos de entrenamiento y prueba utilizando `TimeSeriesSplit`, una técnica que respeta la secuencia temporal al garantizar que los datos de prueba siempre sean posteriores a los de entrenamiento.


En resumen, este conjunto de datos está diseñado para capturar los patrones de la demanda eléctrica en función de factores climáticos y el tipo de consumidor, ofreciendo una base sólida para analizar cómo estas variables interactúan a lo largo del tiempo. Este enfoque permite no solo entender mejor las dinámicas del consumo energético, sino también desarrollar predicciones precisas que pueden apoyar la planificación y la gestión eficiente de los recursos eléctricos.

Resultados obtenidos

3.1 Resultados


En este análisis, evaluamos los resultados obtenidos al aplicar el modelo LSTM para predecir la demanda eléctrica, con el objetivo de entender su desempeño y los factores que influyen en sus

predicciones. A continuación, presentamos una descripción clara y accesible de los hallazgos, manteniendo un tono profesional pero humano.



El rendimiento del modelo LSTM no cumplió con las expectativas. Los valores del coeficiente de determinación (R^2) obtenidos, que incluyen -0.0043, -0.1380 y -0.0849, son negativos, lo que indica que las predicciones del modelo son menos precisas que simplemente usar el promedio de los datos como estimación. Esto sugiere que el modelo no está capturando adecuadamente los patrones de la demanda eléctrica. Además, los valores de error cuadrático medio (RMSE), que oscilan entre 29.23, 31.68 y 30.52, reflejan un error promedio de aproximadamente 30 unidades en las predicciones. Estos errores, aunque consistentes, son significativos y muestran que las predicciones se desvían de los valores reales. La variación observada en los resultados entre los diferentes pliegues (folds) de validación cruzada apunta a una inestabilidad en el modelo, lo que sugiere que su desempeño depende en gran medida de los datos utilizados para el entrenamiento, lo que limita su robustez.

En cuanto a los patrones temporales, el modelo se configuró con un horizonte de 24 horas (`look_back=24`) para capturar patrones diarios en la demanda eléctrica, como picos de consumo en ciertos momentos del día. Sin embargo, los resultados indican que el modelo no logra identificar estos patrones de manera efectiva, lo que podría deberse a limitaciones en su capacidad para procesar las relaciones temporales en los datos.




Las variables independientes utilizadas —temperatura, radiación solar y tipo de consumidor (residencial o industrial)— parecen no estar contribuyendo significativamente a mejorar las predicciones. Esto podría deberse a dos razones principales: o bien las relaciones entre estas variables y la demanda eléctrica no son tan relevantes como se esperaba, o el modelo no está diseñado de manera adecuada para capturar estas conexiones. Por ejemplo, es posible que la temperatura o la radiación solar no tengan un impacto tan directo en la demanda en el contexto de los datos analizados, o que la estructura del modelo no esté aprovechando estas variables de manera efectiva.

Entre los problemas identificados, destaca que el modelo LSTM no está aprendiendo patrones significativos en los datos. La configuración del modelo, que incluye una capa de 50 neuronas, podría ser demasiado compleja para el tamaño del conjunto de datos, que consta de solo 1000 puntos (aproximadamente 42 días). Este volumen de datos puede ser insuficiente para entrenar un modelo LSTM robusto, que requiere grandes cantidades de información para capturar relaciones complejas. Además, la inestabilidad observada en los resultados sugiere que el modelo es sensible a las variaciones en los datos de entrenamiento, lo que podría mejorarse ajustando la arquitectura o recopilando un conjunto de datos más extenso.

3.2 Discusión de los resultados

El análisis de los resultados obtenidos al emplear el modelo de redes neuronales de memoria a corto y largo plazo (LSTM) para predecir la demanda eléctrica revela desafíos significativos en

su desempeño, lo que invita a una reflexión crítica sobre su configuración y las limitaciones del conjunto de datos utilizado.



Los resultados muestran que el modelo LSTM no logró capturar los patrones de la demanda eléctrica de manera efectiva, como lo evidencian los valores negativos del coeficiente de determinación (R^2 : -0.0043, -0.1380, -0.0849). Estos valores indican que las predicciones del modelo son menos precisas que simplemente usar el promedio de los datos, lo que sugiere una incapacidad para modelar las relaciones subyacentes en los datos, (Roy, 2021).

Además, los valores del error cuadrático medio (RMSE: 29.23, 31.68, 30.52) reflejan un error promedio de aproximadamente 30 unidades en las predicciones, lo que representa una desviación significativa de los valores reales. Esta falta de precisión es consistente con observaciones en la literatura, donde se señala que los modelos LSTM pueden enfrentar dificultades cuando los datos no son suficientemente representativos o cuando la arquitectura no está optimizada para el problema específico, (Al-Haddad, 2024).

La variación en los resultados entre los diferentes pliegues de validación cruzada (TimeSeriesSplit) apunta a una inestabilidad del modelo, lo que podría atribuirse a su sensibilidad a las variaciones en los datos de entrenamiento. Esta inestabilidad es un desafío común en modelos de aprendizaje profundo aplicados a series temporales, especialmente cuando el volumen de datos es limitado (Ibrahim, 2022).

El modelo LSTM se configuró con un horizonte de 24 horas (`look_back=24`) para capturar patrones diarios en la demanda eléctrica, como los picos de consumo en horarios específicos. Sin embargo, los resultados indican que no logró identificar estos patrones de manera efectiva. Esto podría deberse a la complejidad inherente de las series temporales en el contexto energético, donde factores como la estacionalidad y las variaciones intradiarias requieren una configuración más robusta del modelo (Philips, 2023).

Estudios previos han destacado que los modelos LSTM son particularmente efectivos para capturar dependencias a largo plazo, pero su rendimiento depende en gran medida de la calidad y cantidad de los datos, así como de la selección adecuada de hiperparámetros, (Belhaiza, 2024).

Las variables independientes utilizadas —temperatura, radiación solar y tipo de consumidor (residencial o industrial)— no parecen haber contribuido significativamente a las predicciones. Esto puede indicar que las relaciones entre estas variables y la demanda eléctrica no son tan fuertes como se esperaba, o que el modelo no está diseñado para aprovechar estas relaciones de manera efectiva. La literatura sugiere que las variables climáticas, como la temperatura, suelen tener un impacto significativo en la demanda eléctrica, especialmente en contextos residenciales donde el uso de aire acondicionado o calefacción es común, (Duan, Xu, Chen & Wang, 2025). Sin embargo, en este caso, la falta de contribución de estas variables podría estar relacionada con la naturaleza simulada del conjunto de datos, que consta de solo 1000 puntos (aproximadamente 42 días). Los modelos de aprendizaje automático, como LSTM, requieren grandes volúmenes de datos para aprender relaciones complejas, y un conjunto de datos limitado puede dificultar la generalización del modelo (Hussain, 2025).

Entre los problemas identificados, destaca que la configuración del modelo, con una capa de 50 neuronas, puede ser demasiado compleja para el tamaño del conjunto de datos. Esto es consistente con observaciones en la literatura, donde se señala que modelos LSTM con arquitecturas complejas pueden sufrir de sobreajuste o inestabilidad cuando los datos son insuficientes (Jain, 2024). Además, la literatura enfatiza la importancia de un preprocesamiento adecuado y la selección de hiperparámetros para mejorar el rendimiento de los modelos LSTM en la predicción de la demanda eléctrica (Amat, 2023).

Por ejemplo, el uso de técnicas como el escalado MinMaxScaler y el manejo de valores faltantes con rellenado hacia adelante (forward fill) es adecuado, pero podría no ser suficiente si las relaciones entre las variables no son lo suficientemente robustas o si el modelo no está optimizado para capturarlas (Allal & Escobra, 2024).

Conclusión

El modelo LSTM no logró predecir de manera efectiva la demanda eléctrica, como lo evidencian los valores negativos de R^2 (-0.0043, -0.1380, -0.0849) y los errores significativos de RMSE (29.23, 31.68, 30.52), lo que indica un desempeño inferior al uso del promedio de los datos como predicción.

Esta limitación parece estar influenciada por varios factores críticos. En primer lugar, el conjunto de datos simulado, con solo 1000 puntos (aproximadamente 42 días), es probablemente insuficiente para entrenar un modelo LSTM complejo, que requiere grandes volúmenes de datos para capturar patrones temporales y relaciones no lineales. En segundo lugar, la arquitectura del modelo, con una capa de 50 neuronas, puede ser demasiado compleja para la cantidad de datos disponible, lo que lleva a inestabilidad y posible sobreajuste.

Además, las variables independientes (temperatura, radiación solar y tipo de consumidor) no parecen haber contribuido significativamente a las predicciones, sugiriendo que las relaciones entre estas variables y la demanda eléctrica no son lo suficientemente fuertes en este conjunto de datos o que el modelo no está optimizado para capturarlas.

Estos resultados demuestran la importancia de alinear la complejidad del modelo con la calidad y cantidad de los datos disponibles, así como de optimizar cuidadosamente los hiperparámetros y las variables de entrada [5]. La literatura sugiere que enfoques híbridos, que combinen modelos de aprendizaje profundo como LSTM con métodos estadísticos tradicionales como ARIMA, podrían mejorar la precisión de las predicciones al aprovechar las fortalezas de ambos enfoques [3]. Asimismo, aumentar el tamaño del conjunto de datos y explorar técnicas de regularización adicionales podrían mitigar los problemas de inestabilidad observados.



En conclusión, este análisis revela que el modelo LSTM, en su configuración actual, no es adecuado para predecir la demanda eléctrica con el conjunto de datos utilizado. Sin embargo, los hallazgos ofrecen una oportunidad valiosa para ajustar la estrategia de modelado, ya sea optimizando la arquitectura del modelo, incrementando el volumen de datos o integrando enfoques híbridos. Estas mejoras podrían conducir a predicciones más precisas, lo que sería crucial para una gestión energética eficiente y sostenible en el contexto de redes inteligentes.

REFERENCIAS

Al-Haddad, Y., Abdu Ibrahim, A., & Naeem, R. (2024). Forecasting energy consumption in smart grids: A comparative analysis of recurrent neural networks. *Iraqi Journal for Computers and Informatics*, 50(1), 123–132. <https://doi.org/10.25195/ijci.v50i1.492>

Ali, B. M. (2023). Load predictions in electrical energy network: Current knowledge and future directions using machine learning. 2023 6th International Conference on Engineering Technology and Its Applications (IICETA), 589–595. <https://doi.org/10.1109/IICETA57613.2023.10351352>

Allal, Z., Noura, H., Salman, O., & Vernier, F. (2024). Predicting power consumption using machine learning techniques. 2024 International Wireless Communications and Mobile Computing (IWCMC), 1522–1527. <https://doi.org/10.1109/IWCMC61514.2024.10592560>

Amat Rodrigo, J., & Escobar Ortiz, J. (2023). Skforecast [Computer software]. Zenodo. <https://doi.org/10.5281/ZENODO.8382788>

Belhaiza, S., & Al-Abdallah, S. (2024). A neural network forecasting approach for the smart grid demand response management problem. *Energies*, 17(10), 2329. <https://doi.org/10.3390/en17102329>

Dahya, T. (2023, December 4). Using Machine Learning to predict US electricity demand: A comparison of two approaches. Medium. <https://medium.com/@tdahya2/predicting-us-electricity-usage-a-comparison-of-two-approaches-34303b81a4aa>

Duan, Y., Xu, Z., Chen, H., & Wang, Y. (2025). Novel machine learning approach for enhanced smart grid power use and price prediction using advanced shark Smell-Tuned flexible support vector machine. *Scientific Reports*, 15(1), 20909. <https://doi.org/10.1038/s41598-025-05083-0>



Hussain, I., Ching, K. B., Uttraphan, C., Tay, K. G., & Noor, A. (2025). Evaluating machine learning algorithms for energy consumption prediction in electric vehicles: A comparative study. *Scientific Reports*, 15(1), 16124. <https://doi.org/10.1038/s41598-025-94946-7>

Ibrahim, B., Rabelo, L., Gutierrez-Franco, E., & Clavijo-Buritica, N. (2022). Machine learning for short-term load forecasting in smart grids. Multidisciplinary Digital Publishing Institute. <https://dspace.mit.edu/handle/1721.1/146313>

Jain, A., & Gupta, S. C. (2024). Evaluation of electrical load demand forecasting using various machine learning algorithms. *Frontiers in Energy Research*, 12, 1408119. <https://doi.org/10.3389/fenrg.2024.1408119>

Lee, S. (n.d.). Revolutionizing smart grids with machine learning. Retrieved July 10, 2025, from <https://www.numberanalytics.com/blog/machine-learning-in-smart-grids>

Machine learning for product demand forecasting—The guide. (n.d.). Slimstock. Retrieved July 10, 2025, from <https://www.slimstock.com/blog/machine-learning/>

Manav. (2023, December 22). The role of ai and machine learning in power price forecasting. Future Bridge Events | Conferences & Summits. <https://future-bridge.eu/the-role-of-ai-and-machine-learning-in-power-price-forecasting/>

Philips, A., & Jayakumar, J. (2023). Time-series based household electricity consumption forecasting. 2023 11th International Conference on Smart Grid (icSmartGrid), 1–15. <https://doi.org/10.1109/icSmartGrid58556.2023.10170973>

Roy, K., Ishmam, A., & Taher, K. A. (2021). Demand forecasting in smart grid using long short-term memory. 2021 International Conference on Automation, Control and Mechatronics for Industry 4.0 (ACMI), 1–5. <https://doi.org/10.1109/ACMI53878.2021.9528277>

Strielkowski, W., Vlasov, A., Selivanov, K., Muraviev, K., & Shakhnov, V. (2023). Prospects and challenges of the machine learning and data-driven methods for the predictive analysis of power systems: A review. *Energies*, 16(10), 4025. <https://doi.org/10.3390/en16104025>

Ugbehe, P. O., Diemuodeke, O. E., & Aikhuele, D. O. (2025). Electricity demand forecasting methodologies and applications: A review. *Sustainable Energy Research*, 12(1), 19. <https://doi.org/10.1186/s40807-025-00149-z>



Conflicto de intereses:

Los autores declaran que no existe conflicto de interés posible.

Financiamiento:

No existió asistencia financiera de partes externas al presente artículo.

Agradecimiento:

N/A

Nota:

El artículo no es producto de una publicación anterior.