Maestría en

INTELIGENCIA ARTIFICIAL APLICADA

Trabajo previo a la obtención de título de Magister en

AUTOR/ES:

Stefany Carol Escobar Molina

Miguel Ángel Cela Sacoto

Diego Paúl Ocaña Urbina

TUTOR/ES:

Pablo Xavier Andrade Montalvo

Andrés Roberto Navas Castellanos

Aplicación de un modelo LSTM (Long Short-Term Memory) multivariable para la predicción del consumo eléctrico a corto plazo en alimentadores de distribución urbanos y rurales de la provincia de Tungurahua, utilizando datos históricos de 2016–2025

Quito - Ecuador

Agosto – 20206

REINVENTEMOS EL FUTURO

Certificación de autoría

Nosotros, **Miguel Ángel Cela Sacoto, Stefany Carol Escobar Molina y Diego Paúl Ocaña Urbina,** declaramos bajo juramento que el trabajo aquí descrito es de nuestra autoría; que no ha sido presentado anteriormente para ningún grado o calificación profesional y que se ha consultado la bibliografía detallada.

Cedemos nuestros derechos de propiedad intelectual a la Universidad Internacional del Ecuador (UIDE), para que sea publicado y divulgado en internet, según lo establecido en la Ley de Propiedad Intelectual, su reglamento y demás disposiciones legales.

Validar únicamente en FirmaEC.
Firmado electrónicamente por:
MIGUEL ANGEL CELA SACOTO

Firma
Miguel Angel Cela Sacoto

Stefany Carol Escobar Molina
Time Stamping Security Data

Firma
Stefany Carol Escobar Molina

Validar únicamente en FirmaEC.
Firmado electrónicamente por:
DIEGO PAUL OCANA URBINA

Firma
Diego Paúl Ocaña Urbina

Autorización de Derechos de Propiedad Intelectual

Nosotros, **Miguel Ángel Cela Sacoto, Stefany Carol Escobar Molina y Diego Paúl Ocaña Urbina**, en calidad de autores del trabajo de investigación titulado ***Aplicación de un modelo LSTM (Long Short-Term Memory) multivariable para la predicción del consumo eléctrico a corto plazo en alimentadores de distribución urbanos y rurales de la provincia de Tungurahua, utilizando datos históricos de 2016–2025***, autorizamos a la Universidad Internacional del Ecuador (UIDE) para hacer uso de todos los contenidos que nos pertenecen o de parte de los que contiene esta obra, con fines estrictamente académicos o de investigación. Los derechos que como autores nos corresponden, lo establecido en los artículos 5, 6, 8, 19 y demás pertinentes de la Ley de Propiedad Intelectual y su Reglamento en Ecuador.

D. M. Quito, agosto 2026

Firma
Miguel Angel Cela Sacoto

Firma
Stefany Carol Escobar Molina

Firma
Diego Paúl Ocaña Urbina

Aprobación de dirección y coordinación del programa

Nosotros, **Alejandro Cortés López Director EIG y Karla Estefanía Mora Cajas Coordinadora UIDE,** declaramos que: **Miguel Ángel Cela Sacoto, Stefany Carol Escobar Molina y Diego Paúl Ocaña Urbina** son los autores exclusivos de la presente investigación y que ésta es original, auténtica y personal de ellos.

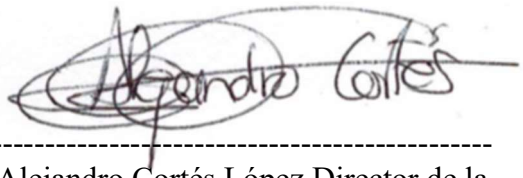

Alejandro Cortés López Director de la Maestría en Inteligencia Artificial Aplicada

---

Karla Estefanía Mora Cajas
Coordinadora de la
Maestría en Inteligencia Artificial Aplicada

DEDICATORIA

[Stefany Carol Escobar Molina]: Dedico este proyecto a Dios, padres e hijo por su apoyo incondicional donde el cansancio era más fuerte que la motivación, pero siempre recibía palabras de aliento para poder continuar, fue un camino difícil pero no imposible y gracias a todo ese apoyo puede completar esta meta muy importante para mi futuro profesional.

[Diego Paúl Ocaña Urbina]: Este proyecto es dedicado a Dios y a mi familia, quienes hicieron posible este logro, Su paciencia, tiempo y amor incondicional inspiraron a dar lo mejor de mí cada día. Su apoyo ha sido fundamental para alcanzar uno de los retos más relevantes en mi vida.

[Miguel Ángel Cela Sacoto]: Dedico este proyecto primeramente a Dios, padres, esposa, hijos y toda la familia, por todo el apoyo brindado durante este camino, ya que no fue un camino duro, pero con su apoyo, ánimos en cada día fue fundamental para completar esta meta.

AGRADECIMIENTOS

Los autores, expresan su profundo agradecimiento a la Universidad Internacional del Ecuador, por brindarnos el espacio, recursos, para el desarrollo de esta investigación, como también a todos los docentes que dictaron esta maestría, ya que compartieron todo su conocimiento y apoyo fue fundamental.

Agradecemos a la Empresa Eléctrica Ambato Regional Centro Norte S.A (EEASA), por brindarnos todo el apoyo para facilitar información necesaria para el desarrollo de esta investigación.

Finalmente, agradecemos a nuestras familias y seres queridos, por todo su apoyo incondicional, paciencia, y ser el pilar fundamental que nos ha ayudado a culminar este proceso académico con éxito.

RESUMEN

El proyecto abarca el diseño, implementación y corroboración de un modelo de red neuronal recurrente LSTM multivariable para realizar la predicción del consumo eléctrico a corto plazo en cinco alimentadores de la Empresa Eléctrica Ambato Regional Centro Norte S.A. (EEASA).

Los cinco alimentadores representan distintos perfiles de consumo (urbano residencial, urbano comercial, rural residencial, rural agrícola-residencial e industrial) con datos históricos del período 2016-2025 a resolución de 15 minutos. El desarrollo fue un proceso iterativo de cuatro versiones (v1 a v4), documentado sobre un alimentador de referencia, para luego replicar las versiones v1 y v4 en los cuatro alimentadores restantes. Las arquitecturas implementadas evidenciaron hallazgos importantes: v1 (línea base) comprobó la necesidad de realizar una partición temporal; exclusión del periodo 2019-2021 (COVID-19) y ventanas de racionamiento por cortes programados (2024); sobre ese régimen corregido, se reformula el objetivo como un residuo respecto a una línea base de persistencia (v4) fue el ajuste que permitió al LSTM superar los umbrales de aceptación establecidos.

La comparación directa frente a métodos clásicos se lo evaluó con métricas de Error Porcentual Absoluto Medio (MAPE), la Raíz del Error Cuadrático Medio (RMSE) y el Error Absoluto Medio (MAE). El modelo final (v4) alcanzo un MAPE entre 2.16% y 5.68% según el alimentador, cumpliendo los umbrales de aceptación teórico (referencia de industria) y el práctico (medido por el coeficiente de variación) por cada alimentador. Frente a métodos clásicos (ARIMA, regresión lineal, media móvil), se evidencia que el modelo LSTM propuesto logro obtener el menor MAPE en todos los alimentadores.

Los resultados obtenidos confirman que la reformulación residual sobre una persistencia diaria constituye la estrategia más eficaz para mejorar la precisión del pronóstico en alimentadores con perfiles de demanda heterogéneos.

***Palabras Clave**:* LSTM, MAPE, RMSE, MAE, EEASA.

ABSTRACT

The project involves the design, implementation, and validation of a multivariate LSTM recurrent neural network model to predict short-term electricity consumption in five feeder lines of Empresa Electrica Ambato Regional Centro Norte S.A. (EEASA).

The five feeders represent different consumption profiles (urban residential, urban commercial, rural residential, rural agricultural-residential, and industrial) with historical data from 2016 to 2025 at a 15-minute resolution. Development was an iterative process involving four versions (v1 through v4), documented using a reference feeder, after which versions v1 and v4 were replicated across the remaining four feeders. The implemented architectures revealed important findings: v1 (baseline) demonstrated the need for temporal partitioning; exclusion of the 2019–2021 period (COVID-19) and rationing windows due to scheduled outages (2024); based on that corrected regime, the objective was reformulated as a residual relative to a persistence baseline (v4)—this adjustment allowed the LSTM to exceed the established acceptance thresholds.

The direct comparison with traditional methods was evaluated using the Mean Absolute Percentage Error (MAPE), Root Mean Square Error (RMSE), and Mean Absolute Error (MAE) metrics. The final model (v4) achieved a MAPE ranging from 2.16% to 5.68% depending on the feeder, meeting both the theoretical (industry benchmark) and practical (measured by the coefficient of variation) acceptance thresholds for each feeder. Compared to classical methods (ARIMA, linear regression, moving average), it is evident that the proposed LSTM model achieved the lowest MAPE across all feeders.

The results confirm that residual reformulation based on daily persistence is the most effective strategy for improving forecast accuracy in feeders with heterogeneous demand profiles.

Keywords: LSTM, MAPE, RMSE, MAE, EEASA.

ÍNDICE

RESUMEN vii

ABSTRACT viii

CAPITULO 1: 1

1. INTRODUCCIÓN 1

1.1. Definición del proyecto 1

1.2. Justificación e importancia del trabajo de investigación 2

1.3. Alcance 3

1.4. Objetivos 3

CAPITULO 2: 5

2. REVISIÓN DE LITERATURA 5

2.1. Estado del Arte 5

2.2. Marco Teórico 6

CAPITULO 3: 17

3. DESARROLLO 17

3.1. Desarrollo del Trabajo 17

3.2. Preprocesamiento y anonimización de datos de Medidores Inteligentes 21

3.3. Diseño y configuración del modelo LSTM multivariable 27

3.4. Entrenamiento y ajuste de hiper-parámetros (entorno Kaggle GPU) 29

3.5. Refinamiento del modelo y variantes evaluadas 30

CAPITULO 4: 32

4. ANÁLISIS DE RESULTADOS 32

4.1. Pruebas de Concepto 32

4.2. Análisis de Resultados 35

CAPITULO 5: 50

5. CONCLUSIONES Y RECOMENDACIONES 50

5.1. Conclusiones generales 50

5.2. Conclusiones específicas 50

5.3. Limitaciones a la Investigación 54

5.4. Recomendaciones 55

Bibliografía 57

Apéndices 62

ÍNDICE DE TABLAS

Tabla 1 Tabla de estructura metodológica implementada 6

Tabla 2 Investigaciones relevantes 10

Tabla 3 Tabla de features implementados 17

Tabla 4 Resumen de análisis por alimentador 22

Tabla 5 Definición de Umbral Práctico y Teórico 30

Tabla 6 Comparación versiones MAPE (ALGR) 30

Tabla 7 Comparación MAPE v1-v4 Modelo LSTM 31

Tabla 8 Listado de Problemas Detectados 32

Tabla 9 Lista de Errores de TimeStamp 33

Tabla 10 Listado de variables definidas 34

Tabla 11 Comparación LSTM v1, v4 35

Tabla 12 Comparativo resultados con Otros Modelos de Predicción 38

Tabla 13 Cumplimiento de Modelos Predictivos por Alimentador 41

INDICE DE FIGURAS

Figuras 1 Preparación de datos 19
Figuras 2 Evolución de entrenamiento (v1 a v5) 20
Figuras 3 Exportación de Predicciones 20
Figuras 4 Calidad del Dataset ALIN 23
Figuras 5 Calidad del Dataset ALUC 24
Figuras 6 Calidad del Dataset ALUR 25
Figuras 7 Calidad del Dataset ALRA 26
Figuras 8 Calidad del Dataset ALRG 27
Figuras 9 Comparación Versiones MAPE (ALRG) 31
Figuras 10 Comparación Alimentador LSTM V1 vs V4 36
Figuras 11 Comparativa Resultado Modelos Alimentados ALIN 38
Figuras 12 Comparativa Resultado Modelos Alimentados ALUC 39
Figuras 13 Comparativa Resultado Modelos Alimentados ALUR 39
Figuras 14 Comparativa Resultado Modelos Alimentados ALRA 40
Figuras 15 Comparativa Resultado Modelos Alimentados ALRG 40
Figuras 16 Tasa de cumplimiento entre modelos Predictivos 42
Figuras 17 Ejemplo predicción V1 vs V4 para ALIN 44
Figuras 18 Ejemplo predicción V1 vs V4 para ALUC 44
Figuras 19 Ejemplo predicción V1 vs V4 para ALUR 45
Figuras 20 Ejemplo predicción V1 vs V4 para ALRA 45
Figuras 21 Ejemplo predicción V1 vs V4 para ALRG 46
Figuras 22 Dashboard LSTM por Alimentador 47
Figuras 23 Dashboard, visualización metricas por alimentador 48
Figuras 24 Dashboard comparación real vs predicción 49

CAPITULO 1:

1. INTRODUCCIÓN

1.1. Definición del proyecto

El Proyecto consiste en el diseño, implementación y verificación del modelo LSTM (Long Short-Term Memory) en redes neuronales recurrente, en la predicción del consumo eléctrico a corto plazo para alimentadores de distribución de zonas urbanas y rurales de la provincia de Tungurahua. Se emplearon datos históricos entre los años 2016 al 2025, con el principal objetivo de identificar patrones temporales que permitan anticipar el consumo energético en los días e intervalos de horas.

Entre las variables de entrada que integran el proyecto se encuentra el consumo de energía activa (kWh), energía reactiva (kVARh), características temporales cíclicas y variables derivadas del comportamiento histórico de la demanda cuyo objetivo es capturar patrones complejos y dependencias a largo plazo relacionados a las series de tiempo eléctricas. El límite de predicción objetivo es de una hora hacia adelante, con un intervalo de 15 minutos, utilizando un historial de 24 horas como entrada.

Los sistemas de distribución eléctrica en zonas de desarrollo presentan un reto consistente y de crecimiento como es la previsión del consumo de la energía eléctrica a nivel de líneas de distribución. En la provincia de Tungurahua, los alimentadores de distribución son objetos permanentes de revisión para la toma de decisiones operacionales con respecto a la gestión de la carga, el equilibrio de la red, la programación del mantenimiento. Las decisiones son actualmente tomadas mediante modelos de regresión lineal aplicados únicamente a la demanda total de la concesión, sin que exista un sistema formal de predicción a nivel de alimentador individual. Esta brecha impide anticipar comportamientos diferenciados por tipo de carga y zona geográfica, y es precisamente el vacío que el presente proyecto busca resolver.

El problema fundamental es que el consumo eléctrico en alimentadores de distribución es altamente dinámico con series temporales multivariantes, influenciado por horas del día, día de la semana, ciclos de actividades económicas, estaciones de agricultura y feriados. Los métodos de previsión son insuficientes para modelar estas interdependencias dando lugar a sobrecapacidad (capacidad desperdiciada y mayores costos operativos) o una incapacidad (inestabilidad de voltaje, sobrecargas e interrupciones de servicio).

El proyecto abarca alimentadores de la provincia de Tungurahua de la red eléctrica de distribución operada por la EEASA (Empresa Eléctrica de Ambato S.A.) Los cantones seleccionados representan 5 perfiles distintos: urbano residencial, urbano comercial, rural residencial, rural agrícola-residencial e industrial. Esta diversidad socioeconómica hace que el Dataset sea valioso para poder abarcar un gran margen de argumentos para modelar.

1.2. Justificación e importancia del trabajo de investigación

Desde el punto de vista técnico, es importante estudiar este tema porque los métodos clásicos de pronóstico, como los modelos ARIMA, la regresión lineal o las medias móviles, no pueden capturar bien las no linealidades, estacionalidades múltiples y la alta variabilidad intradiaria presente en los alimentadores de distribución. Las redes LSTM son una alternativa mejor porque pueden aprender dependencias temporales a largo plazo mediante mecanismos de compuertas.

Desde el punto de vista práctico, mejorar la precisión del pronóstico de demanda permite a EEASA hacer varias cosas:

- Reducir costos operativos.
- Reducir los márgenes de reserva innecesarios y mejorar la eficiencia económica.

• Planificar de forma proactiva el mantenimiento preventivo de equipos en subestaciones y alimentadores.

• Anticipar picos de demanda en alimentadores rurales, donde la infraestructura tiene menor capacidad de respuesta.

• Facilitar la integración futura de energías renovables y vehículos eléctricos en la red de distribución.

Desde el punto de vista académico, esta investigación contribuye al conocimiento local sobre la aplicación de inteligencia artificial en sistemas eléctricos de potencia, que es un área poco explorada en el contexto de las empresas distribuidoras ecuatorianas. Los resultados pueden servir como referencia para estudios similares en otras provincias del Sistema Nacional Interconectado.

La disponibilidad de datos históricos de medición con resolución de 15 minutos proporcionados por EEASA, que abarcan el período 2016-2025, es una base sólida y representativa para entrenar, validar y probar el modelo, lo que garantiza la solidez estadística de los resultados obtenidos.

1.3. Alcance

El alcance del presente proyecto se define en las siguientes dimensiones, delimitando con precisión los parámetros técnico, geográfico, temporal y operativo del trabajo de investigación, de manera que los resultados sean reproducibles, evaluables y aplicables en el contexto del sistema de distribución de la Empresa Eléctrica Ambato S.A. (EEASA).

1.4. Objetivos

1.4.1. Objetivo general

Implementar el modelo LSTM (Long Short-Term Memory) multivariable para la predicción del consumo eléctrico a corto plazo en alimentadores de distribución urbanos y

rurales de la provincia de Tungurahua en los cantones Ambato, Pelileo y Píllaro, utilizando datos históricos de los años 2016 al 2025, con el propósito de mejorar la confiabilidad del sistema eléctrico y optimizar la planificación operativa y contribución a la eficiencia energética en la región.

1.4.2. Objetivo especifico

- Depurar los datos de consumo de electricidad de los cantones Ambato, Pelileo y Píllaro, desde 2016 hasta 2025. Esto incluye identificar patrones, anomalías y cambios estacionales en el consumo.
- Diseñar un conjunto de variables de contexto (calendario, festividades y estadísticos derivados de la demanda histórica) que integre los factores temporales relevantes para el modelo de predicción.
- Desarrollar el modelo de red neuronal para maximizar su precisión predictiva, evaluando su rendimiento utilizando las métricas MAPE, RMSE y MAE.
- Determinar el desempeño comparativo del modelo LSTM frente a métodos clásicos de predicción (regresión lineal, ARIMA y medias móviles) en alimentadores urbanos y rurales.
- Analizar los resultados obtenidos por tipo de alimentador y formular recomendaciones técnicas para su aplicación en entornos de operación real de la EEASA.

CAPITULO 2:

2. REVISIÓN DE LITERATURA

2.1. Estado del Arte

El uso de la inteligencia artificial en la predicción de series temporales es empleado con mayor frecuencia en los últimos años, particularmente en dominios donde la disponibilidad de datos históricos de alta resolución permite modelar relaciones no lineales complejas, como es el caso del pronóstico de demanda eléctrica (Hasanat et al., 2025).

La predicción de la demanda eléctrica a corto plazo (Short-Term Load Forecasting, STLF) constituye un problema clásico de la planificación operativa en sistemas de distribución eléctrica. Su resolución ha evolucionado desde métodos estadísticos clásicos hasta arquitecturas de aprendizaje profundo capaces de capturar relaciones no lineales y dependencias temporales de largo plazo en las series de consumo (Haq & Ni, 2021).

El presente capítulo tiene como finalidad establecer el marco teórico y conceptual que sustenta el desarrollo de la investigación. Para ello, se organiza en tres bloques principales: el bosquejo de la estructura general del trabajo, el estado del arte que sintetiza los avances científicos más relevantes en predicción de demanda eléctrica mediante inteligencia artificial, y la descripción detallada de los conjuntos de datos utilizados.

La investigación sigue una estructura metodológica secuencial dividida en cinco fases interrelacionadas, tal como se describe a continuación:

Tabla 1

Tabla de estructura metodológica implementada

Fase	Nombre	Actividades principales
1	Adquisición y exploración de datos	Recopilación de datos EEASA; análisis exploratorio; detección de valores atípicos y huecos.
2	Preprocesamiento e ingeniería de variables	Imputación de datos faltantes; creación de features temporales cíclicas, lags y estadísticas de ventana móvil; normalización.
3	Diseño y entrenamiento del modelo LSTM	Definición de arquitectura; ajuste de hiper parámetros; entrenamiento con datos 2016–2026; validación cruzada temporal.
4	Evaluación y comparación de modelos	Cálculo de métricas MAE, RMSE y MAPE; comparación con ARIMA, regresión lineal y medias móviles; pruebas estadísticas de significancia.
5	Análisis de resultados y conclusiones	Interpretación por tipo de alimentador (urbano/rural); análisis de errores; recomendaciones para EEASA.

Nota. Elaboración propia de los autores

La predicción de demanda eléctrica (PDE) ha evolucionado desde los métodos estadísticos clásicos basados en relaciones matemáticas relativamente simples, hacia arquitecturas de aprendizaje profundo capaces de modelar relaciones no lineales y dependencias temporales complejas presentes en el comportamiento del consumo eléctrico (Haq & Ni, 2021).

2.2. Marco Teórico

2.2.1. Métodos clásicos para la predicción de demanda eléctrica

Durante mucho tiempo específicamente entre las décadas de 1980 a 2010 se han usado métodos tradicionales para los pronósticos de series de tiempo, entre los cuales se

encuentran el modelo llamado ARIMA (Box & Jenkins, 1970). Hasanat et al. (2025) documentan que estos métodos resultan insuficientes para las redes eléctricas inteligentes (smart grids) actuales, dada su limitada capacidad para capturar no linealidades y estacionalidades múltiples.

Este enfoque equivale, en términos metodológicos, a un modelo de persistencia ingenua, ya que asume que el valor futuro será igual al valor observado en el periodo inmediatamente anterior, lo cual solo resulta preciso cuando el patrón de consumo permanece estable, condición que rara vez se cumple en alimentadores con alta variabilidad estructural (Alfares & Nazeeruddin, 2002).

2.2.2. Redes recurrentes y consolidación de LSTM

En la actualidad el estándar para series temporales es la arquitectura LSTM (Long Short-Term Memory), debido a la capacidad que tiene para recordar patrones a largo plazo mediante su estructura de celdas y compuertas (Hochreiter & Schmidhuber, 1997), las cuales deciden qué información pasada es relevante para la predicción y cuál puede descartarse (Hasanat et al., 2025)

Las redes LSTM son una variante más compleja de una RNN debido a que cuentan con la capacidad de aprender secuencias a largo plazo y las herramientas necesarias para olvidar información irrelevante, lo que las hace especialmente adecuadas para el pronóstico de demanda eléctrica multivariante (Haq & Ni, 2021).

Dentro del aprendizaje profundo existe una estrategia complementaria, la cual consiste en reformular el objetivo de predicción como un residuo respecto a una línea base conocida, en lugar de estimar directamente el valor absoluto de la variable objetivo; este principio, conocido como aprendizaje residual, fue introducido por primera vez en el reconocimiento de imágenes (He et al., 2016) y ha sido adaptado posteriormente al pronóstico de demanda eléctrica a corto plazo, donde reformular el objetivo como la

corrección sobre una línea base de persistencia mejora la estabilidad del entrenamiento y la precisión frente a arquitecturas que predicen el valor absoluto directamente (Liu et al., 2025).

2.2.3. Mecanismos de atención y Transformers

Entre los años 2023 y 2026 los mecanismos de atención y las arquitecturas Transformer (Vaswani et al., 2017) han ganado protagonismo en la predicción de series temporales eléctricas, al permitir ponderar simultáneamente la relevancia de distintos puntos de la secuencia histórica en lugar de procesarla estrictamente en orden, como lo hace una LSTM (Ertürk et al., 2026). Estudios comparativos reportan que las mejoras de precisión de los Transformers se concentran principalmente en horizontes de mediano y largo plazo, sin superar de forma consistente al LSTM en el horizonte de corto plazo (Giacomazzi et al., 2023), mientras que su mayor costo computacional de entrenamiento (Hertel et al., 2023) hace que la arquitectura LSTM continúe siendo una opción robusta y eficiente para el horizonte de corto plazo abordado en este estudio.

Las RNN, LSTM y redes recurrentes han sido establecidas como enfoques de vanguardia para el modelado de secuencias y problemas de transducción, como la traducción automática (Vaswani et al., 2017).

Frente al problema de comprensión de información en modelos encoder-decoder, el mecanismo de atención es la solución más optima, debido a que cuando una secuencia de entrada tenía que representarse en un solo vector de longitud fija, se degradaba notablemente el desempeño en secuencias largas. Bahdanau et al. (2015) plantearon permitir que el decodificador “atienda” a distintas partes de las secuencias de entrada en cada paso de una forma selectiva, para no depender de una representación comprimida. Luego, Luong et al. (2015) organizaron variantes de este mecanismo, para poder distinguir entre atención global y local.

2.2.4. Modelos híbridos

Gómez Morales (2024) documenta que buena parte de las limitaciones reportadas en los modelos de predicción de demanda se deben a la falta de datos limpios y consistentes, más que a limitaciones intrínsecas de la arquitectura empleada. En paralelo, los modelos híbridos CNN-LSTM han ganado relevancia reciente: la componente convolucional extrae patrones de correlación entre variables de entrada, mientras que la componente LSTM captura la dependencia temporal de la serie, lo que en varios estudios produce mejoras de precisión frente a arquitecturas LSTM puras (Hasanat et al., 2025).

2.2.5. Método actual de predicción en EEASA y valor agregado de la IA

La EEASA realiza actualmente proyecciones de demanda exclusivamente a nivel de empresa (demanda total del sistema de concesión), utilizando modelos de regresión lineal sobre datos históricos mensuales. A nivel de alimentador individual no se aplica ningún modelo de predicción, la operación de cada alimentador se basa en el comportamiento histórico promedio observado por los operadores del CECON. Esta brecha representa precisamente la oportunidad que justifica el presente proyecto.

Los modelos de regresión lineal asumen una relación proporcional y estacionaria entre las variables predictoras y la demanda, lo que resulta insuficiente frente a la naturaleza altamente no lineal, multivariante y con múltiples estacionalidades del consumo en los alimentadores de distribución. La demanda eléctrica a nivel de alimentador está influenciada simultáneamente por ciclos horarios, diarios, semanales y anuales, además de eventos atípicos como feriados, los ciclos agrícolas (en el caso de Pelileo y Píllaro) y las perturbaciones de gran escala como fue la pandemia de 2020. La regresión lineal no puede capturar estas interdependencias no lineales ni las dependencias temporales de largo plazo presentes en series de nueve años de datos a resolución de 15 minutos.

El valor agregado del modelo LSTM multivariable propuesto tiene cuatro dimensiones:

- La capacidad de modelar dependencias temporales de largo plazo mediante el mecanismo de puertas de la arquitectura LSTM, las cuales aprenderán qué información histórica es relevante y cuál puede descartarse (Hasanat et al., 2025);
- La integración de variables multivariantes —energía activa, reactiva, variables temporales cíclicas y estadísticas de ventana móvil—, que enriquecen la capacidad predictiva sin requerir un modelado de cada interacción;
- La adaptabilidad automática a los cinco perfiles de demanda identificados (urbano, comercial, rural, industrial, agrícola) mediante el ajuste de hiper parámetros por alimentador; y
- La actualización continua del modelo con datos nuevos, lo que permite que el sistema aprenda cambios estructurales en el patrón de consumo sin necesidad de rediseño. Estudios de referencia documentan que los modelos LSTM e híbridos CNN-LSTM superan consistentemente a la regresión lineal y a los modelos ARIMA en escenarios de demanda multivariante de corto plazo (Hasanat et al., 2025; Haq & Ni, 2021).

2.2.6. Resumen de investigaciones relevantes

Tabla 2

Investigaciones relevantes

Referencia	Año	Enfoque	Aporte Principal
MDPI (Energies)	2026	Híbrido Transformer	Supera a las LSTM en predicciones de largo plazo (más de 24 horas). (Ertürk, 2026)

Hasanat et al.	2025	CNN-LSTM + Attention	Utiliza "Atención Suave" para priorizar los picos de demanda máxima.
PUCE Ecuador	2024	Deep Learning Local	Evaluación de LSTM en redes de distribución con variables climáticas locales. (Gómez Morales, 2024)
Giacomazzi et al.	2023	Transformer (TFT) vs. LSTM por horizonte	El Transformer no supera al LSTM en pronóstico day-ahead; su ventaja solo aparece en horizonte semanal.
Hertel et al.	2023.	Estrategias de entrenamiento de Transformers	El LSTM entrena consistentemente más rápido que el Transformer bajo la misma estrategia de entrenamiento
Haq & Ni	2021	Modelo híbrido para STLF.	Documenta que el rango de 15 minutos a 1 hora es la ventana óptima para pronóstico a nivel de alimentador de distribución.

Nota. Elaboración propia de los autores

Estos estudios reflejan una tendencia clara y dependiente del horizonte de predicción, los recientes favorecen a las arquitecturas híbridas o basadas en atención por encima de LSTM puras principalmente cuando el horizonte se extiende más allá de un día (Ertürk et al., 2026) o cuando se dispone de variables auxiliares ricas como datos de medidores inteligentes (Hasanat et al., 2025). Sin embargo, para horizontes de corto plazo estas arquitecturas no tiene ventaja como en el estudio realizado por Giacomazzi et al. (2023), al encontrar que un Temporal Fusion Transformer no supera a un LSTM en pronósticos day-ahead, esta superioridad solo aparece en horizontes semanales, y Hertel et al. (2023) documentan que el LSTM entrena de forma más eficiente que el Transformer,

un factor relevante cuando el modelo debe entrenarse de forma independiente para múltiples alimentadores, como en el presente estudio.

La evidencia es consistente con los hallazgos de Haq y Ni (2021), quienes ya documentaban que el rango de 15 minutos a 1 hora constituye la ventana óptima para el pronóstico a nivel de alimentador de distribución. Adicionalmente, ninguno de los estudios revisados aborda de forma simultánea múltiples perfiles de demanda heterogéneos (urbano, rural, agrícola e industrial) dentro de una misma área de concesión, ni evalúa el desempeño diferenciado del modelo por tipo de alimentador (limitación también señalada por Gómez Morales (2024) para el contexto ecuatoriano). El horizonte óptimo y de heterogeneidad de perfiles es precisamente lo que aborda el presente trabajo, al entrenar y evaluar de forma independiente un modelo LSTM multivariable de corto plazo sobre cinco alimentadores con perfiles de demanda distintos dentro de la concesión de la EEASA.

Esta sección describe el diseño metodológico que se aplicó para realizar la parte experimental del proyecto, complementando el bosquejo general presentado en la sección 3.1 y la Tabla 2.

2.2.7. Enfoque y tipo de investigación

El problema de pronóstico de demanda eléctrica se aborda a partir de mediciones numéricas (potencia activa, tensión, corriente, entre otras variables), siendo una investigación con enfoque cuantitativo, donde se evalúa mediante métricas estadísticas de error (MAE, RMSE y MAPE) (Hernández-Sampieri & Mendoza, 2018). Por su finalidad, corresponde a una investigación aplicada de tipo tecnológico, orientada a resolver la problemática sobre la ausencia de análisis predictivos y operativos de los alimentadores de una subestación eléctrica en concreto de la EEASA mediante el desarrollo de un modelo de aprendizaje profundo, y no a la generación de conocimiento teórico.

El estudio es de tipo explicativo-predictivo, ya que no se limita a describir el comportamiento histórico de la demanda, sino a explicar sus patrones estacionales y predecir su comportamiento futuro a partir de variables de entrada multivariables.

2.2.8. Diseño de la investigación

El diseño de esta investigación es no experimental, longitudinal y de series de tiempo. Es no experimental debido a que las variables de consumo eléctrico no son manipuladas por los investigadores, sino observadas tal como ocurren en la operación normal de la red de distribución eléctrica. Es longitudinal porque se analiza la evolución del consumo a lo largo de un periodo extenso y continuo (enero de 2016 a diciembre de 2025), y de series de tiempo porque cada observación mantiene una dependencia temporal explícita respecto de sus valores anteriores (Hernández-Sampieri & Mendoza, 2018).

2.2.9. Población y muestra

La población de estudio corresponde a los alimentadores de distribución eléctrica administrados por la EEASA en la provincia de Tungurahua, específicamente a los cantones Ambato, Pelileo y Píllaro. La muestra, de tipo no probabilístico e intencional, se conforma por cinco alimentadores pertenecientes a los cantones mencionados y seleccionados por representar los cinco perfiles de demanda descritos en la sección 3.3.1 (urbano residencial, urbano comercial, rural residencial, rural agrícola-residencial e industrial). Esta selección intencional garantiza cobertura de la heterogeneidad socioeconómica de la red sin requerir el procesamiento de la totalidad de alimentadores de la concesión.

2.2.10. Técnicas e instrumentos de recolección y procesamiento de datos

La técnica de recolección es la revisión documental de registros de medición de los medidores inteligentes, provistos directamente por el Centro de Control Regional

(CECON) de la EEASA en intervalos de 15 minutos. Como instrumentos de procesamiento y modelado se emplean Python 3 y las bibliotecas Pandas y NumPy para el preprocesamiento; TensorFlow/Keras para el diseño y entrenamiento de los modelos LSTM; y entornos de cómputo diferenciados según la etapa: estaciones locales sin GPU para el preprocesamiento y GPU de la plataforma Kaggle orientada a la ciencia de datos y el aprendizaje automático (Machine Learning) para el entrenamiento e hiper parametrización.

2.2.11. Justificación técnica del horizonte de predicción

La selección del horizonte de predicción de una hora (4 pasos de 15 minutos) se fundamenta en tres argumentos complementarios de naturaleza técnica y operativa.

Estándar internacional de la predicción de demanda a corto plazo (STLF).

Short-Term Load Forecasting (STLF) define el horizonte de una hora como la ventana de referencia dominante para decisiones operativas en sistemas de distribución. Haq y Ni (2021) (2021) e Ibrahim et al. (2022) documentan que el rango entre 15 minutos y 1 hora es el más empleado a nivel de alimentadores de distribución, ya que representa el equilibrio óptimo entre la acción operativa posible y la precisión alcanzable por los modelos. Por el contrario, si se utiliza horizontes inferiores (5 min), los modelos presentarán alta varianza estocástica, mientras que al utilizar horizontes superiores (4–24 h) acumularán error de manera acelerada cuando no se dispone de variables como los pronósticos meteorológicos (Alfares & Nazeeruddin, 2002; Taylor, 2012).

Desde el año 2021 el campo del pronóstico con respecto a la demanda eléctrica a corto plazo ha experimentado un crecimiento muy significante, con más de 100 publicaciones anuales (Dong et al., 2025). En una revisión más reciente y exhaustiva (Eren & Kucukdemiral, 2024) ratifica que el MAPE sigue siendo la métrica de evolución universal.

Alineación con el ciclo de despacho del operador nacional CENACE.

El CENACE emite el despacho económico diario programado del Sistema Nacional Interconectado (SNI) con resolución horaria, y en su Informe Anual 2024 documenta la implementación de redes LSTM para pronósticos de demanda con el mismo horizonte temporal (CENACE, 2024). Esto confirma que la ventana escogida de 1 hora es coherente con la frecuencia de actualización de planes operativos en el contexto ecuatoriano. Aunque la EEASA actualmente no realiza predicciones a nivel de alimentador individual, la adopción de esta ventana de tiempo permite que los resultados del modelo sean directamente compatibles con los flujos de información operativa del SNI, lo que facilita su eventual integración futura.

Viabilidad operativa para la gestión de picos de demanda.

Un horizonte de 1 hora proporciona tiempo suficiente para que los operadores del Centro de Control Regional (CECON) de EEASA puedan ejecutar acciones preventivas, que en la actualidad no se efectúan ya que las decisiones se toman en tiempo real basándose en las curvas de carga de cada alimentador, estas acciones beneficiaran a la operación en las subestaciones como son: la redirección de carga entre alimentadores, activación de capacitores de compensación reactiva o programación de mantenimiento de emergencia, sin que la ventana sea tan amplia que la incertidumbre acumulada degrade la utilidad práctica del pronóstico. Esta ventana es consistente con los tiempos de respuesta documentados en sistemas de distribución latinoamericanos de escala similar (Gómez Morales, 2024)

Según Dai et al. (2021), un pronóstico de picos de demanda confiable permite a los operadores anticipar el momento y la magnitud de los picos con suficiente antelación para así poder activar mecanismos de gestión, tales como la respuesta a la demanda, despacho de reservas o el control directo de carga, obviando así configuraciones costosas y sobredimensionadas. Darwazeh et al. (2022) identifican que las estrategias de

gestión de picos, desde el control de cargas hasta las tarifas diferenciadas por horario, dependen críticamente de la calidad del pronóstico subyacente para su implementación efectiva.

2.2.12. Validez y confiabilidad

La validez del estudio se basa en la partición cronológica de los datos en los distintos conjuntos de entrenamiento, validación y prueba, evitando fugas de información temporal (data leakage) entre periodos (Bergmeir & Benítez, 2012). La confiabilidad de los resultados se controla fijando semillas aleatorias, versionando los notebooks utilizados y almacenando los escaladores y pesos entrenados de cada modelo, de forma que el proceso completo sea reproducible. La evaluación del desempeño se realiza mediante los indicadores MAE, RMSE y MAPE, comparando cada modelo LSTM frente a una línea base de persistencia y frente a métodos clásicos de pronóstico.

CAPITULO 3:

3. DESARROLLO

3.1. Desarrollo del Trabajo

En esta etapa el enfoque general se basa en el desarrollo de un modelo para el pronóstico de carga a corto plazo (STLF) implementado en los cinco alimentadores de EEASA, para lo cual se procede a realizar un pipeline dividido en 3 etapas, cada una de estas etapas fueron mapeando hallazgos experimentales procedentes de la etapa anterior.

Primera etapa: se realizó la preparación de datos para los cinco alimentadores (ALIN, ALUC, ALUR, ALRA, ALRG) con una resolución de 15 minutos, también se construyó un grupo de 26 variables predictoras.

Tabla 3

Tabla de features implementados

Grupo	Variables	Justificación
Eléctrica	kw_activa, kvar_reactiva, fp	Señal objetivo + contexto de carga reactiva
Cíclica temporal	sin/cos de hora, día, mes, semana	Encoding sin/cos evita discontinuidades en medianoche y domingo
Calendario binaria	fin_semana, lunes, viernes, feriado	El alimentador rural tiene perfiles claramente distintos en días especiales
Lags	t-1h, t-2h, t-24h, t-48h, t-7días	El valor de ayer a la misma hora es el predictor más fuerte para STLF
Rolling 24h	media, std, max, min, rango	Contexto del nivel de actividad reciente del alimentador

Nota. Listado de features implementados.

Segunda etapa: se realizó el desarrollo metodológico completo de cuatro versiones del modelo LSTM (v1 = (versión 1) a v4= (versión 4)) para un solo alimentador (ALRG), evaluadas en un horizonte de 1h (4 pasos).

Tercera etapa: se entrenó y aplico para los cuatro alimentadores faltantes el conocimiento metodológico que se aplicó al alimentador ALRG, considerando v1 como línea base y v4 como la formulación final del residuo, de esta manera se confirmó que para los cinco alimentadores la v4 fue la que mejor desempeño obtuvo.

Se utilizaron dos entornos:

Visual Studio Code local para el preprocesamiento, es decir el acceso directo a los CSV de los medidores Inteligentes, en este caso sin necesidad de GPU.

Figuras 1

Preparación de datos

Nota. Se evidencia la etapa de preparación de datos, desde archivos de los medidores inteligentes por cada alimentador

Kaggle GPU P100 para el entrenamiento (ya que fue importante para el uso de carga computacional de 20 modelos, el cual equivale a 5 alimentadores x 4 versiones).

Figuras 2

Evolución de entrenamiento (v1 a v5)

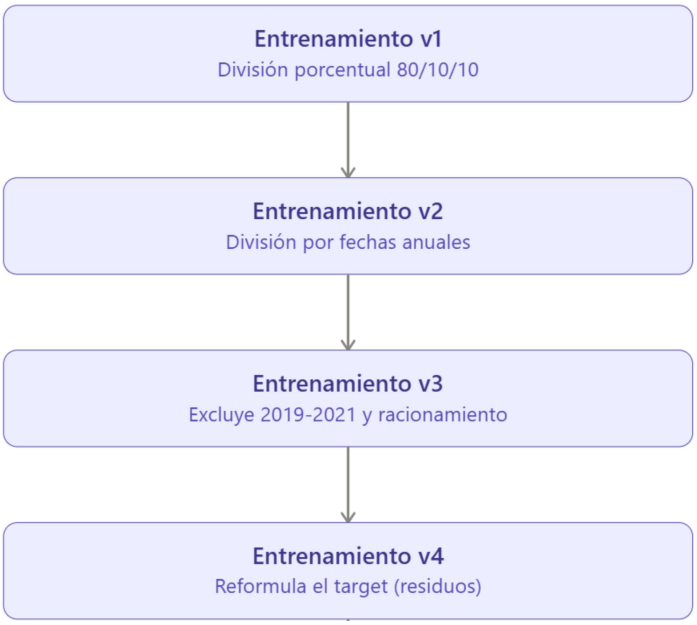

Nota. Evidencia de cuatro versiones de entrenamiento, desde la división porcentual 80/10/10 hasta la reformulación del target (residuos).

Figuras 3

Exportación de Predicciones

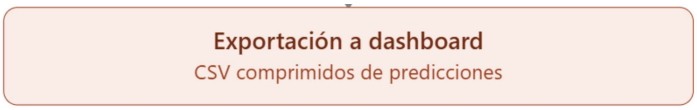

Nota: Salida de csv comprimidos de predicciones.

Como medida de reproducibilidad se utilizó lo siguiente:

- Semilla Fija (np, random.seed (42), tf.random.set_seed (42))
- Escaladores y pesos de modelos (.pkl, .keras)

- Predicciones por alimentador (.csv)

3.2. Preprocesamiento y anonimización de datos de Medidores Inteligentes

Antes de cualquier procesamiento, los códigos reales de los alimentadores de EEASA se reasignaron mediante un script externo a identificadores anonimizados ALIN, ALUC, ALUR, ALRA, ALRG, organizando los archivos mensuales en carpetas por categoría de alimentador, el notebook de esta fase parte ya, de esa estructura anonimizada.

El primer reto técnico fue la heterogeneidad de los propios archivos de medidores inteligentes. No todos los medidores exportan el mismo esquema de columnas: se identificaron tres tipos, uno trifásico completo con 17 variables (donde la potencia activa se obtiene sumando las tres fases), y dos esquemas más simples con 5 y 9 variables respectivamente, donde la potencia se toma directamente de la energía activa del intervalo. La detección del tipo de medidor se automatizó comparando el conjunto de columnas del archivo contra los esquemas conocidos, lo que permitió que un mismo alimentador pudiera cambiar de medidor a mitad de su historial sin que el pipeline fallara.

El segundo reto fue el parsing de fechas. Se encontraron tres formatos de timestamp distintos entre archivos, y un caso particularmente problemático en el que la columna de fecha aparecía completamente en cero por una pérdida total del timestamp durante un gap de mantenimiento del medidor, en ese caso la fecha de inicio se reconstruyó a partir del propio nombre del archivo. Además, se añadió una validación de rango (2016-01-01 a 2025-12-31) para descartar cualquier timestamp corrupto antes de que contaminara el período consolidado de un alimentador.

Con los archivos integrados de forma cronológica, se aplicó un control de calidad : reindexado a una malla exacta de 15 minutos, marcado de gaps de mantenimiento

(meses con 80% o más de registros en cero), imputación por interpolación lineal limitada a huecos de comunicación de hasta 2 horas, dejando como NaN los huecos mayores, para no fabricar datos sintéticos, y marcado (no eliminación) de valores atípicos por encima de 4 desviaciones estándar de la media, asegurando así los picos de demanda industrial reales. En base a la serie limpia se construyeron las mismas 26 variables descritas en la sección 3.3: codificación cíclica del tiempo, indicadores de calendario, lags de potencia y estadísticos móviles de 24 horas.

Todo el proceso se ejecutó de forma local (sin GPU, 16 GB de RAM), procesando los cinco alimentadores de manera secuencial y liberando memoria entre uno y otro, dado que el volumen de datos es hasta diez años de historia por alimentador a resolución de 15 minutos, no permitía mantenerlos todos en memoria simultáneamente. Por cada alimentador se exportaron los tensores de entrada al modelo, los escaladores ajustados, un reporte de calidad y el Dataset limpio en CSV, información que alimentan directamente la fase de entrenamiento.

Tabla 4

Resumen de análisis por alimentador

Alimentador	Completitud	Huecos de comunicación	Outliers marcados	kW media	CV (std/media)
ALIN	99.04%	3,436	3,503	163.11	1.039
ALUC	98.69%	4,646	161	484.21	0.884
ALUR	97.64%	8,501	1,319	451.43	1.043
ALRA	98.07%	7,213	879	565.87	0.812
ALRG	96.80%	11,243	69	463.78	0.933

Nota. Se detalla el análisis por alimentador el cual se evidencia que los outliers fueron identificados por criterio de detección definido en la limpieza de datos. El coeficiente de

variación (desviación estándar/media), utilizado posteriormente para calibrar el umbral practico de aceptación.

Figuras 4

Calidad del Dataset ALIN

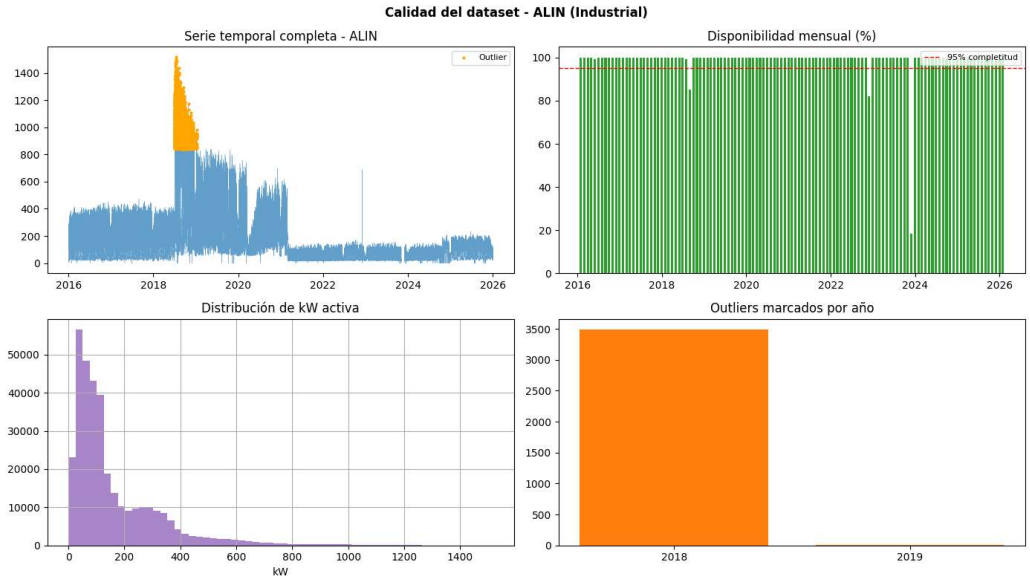

Nota: Se evidencia una completitud del 99.04% | *CV (std/media) del 1.039 (este valor es el que calibra el umbral práctico de ALIN) .*

Los outliers se concentran en (2018, 2019), coincidiendo con (2019) evidencia del régimen atípico 2019-2021 excluido del entrenamiento. CV=1.039 consistente con una demanda industrial aperiódica y dependiente de procesos, no de calendario.

ALIN — Industrial (CV = 1.039, el segundo más alto)

Completitud 99.04% — la más alta de los 5 (mejor calidad de comunicación de los medidores inteligentes).

Solo 7 huecos grandes sin imputar — la mayoría de sus 3,436 huecos fueron chicos e interpolables.

3,503 outliers marcados — **por mucho** el valor más alto de los 5 (2.7× el segundo lugar, ALUR con 1,319).

kW media (163.11) la más baja de los 5, pero kW std (169.50) la supera.

Figuras 5

Calidad del Dataset ALUC

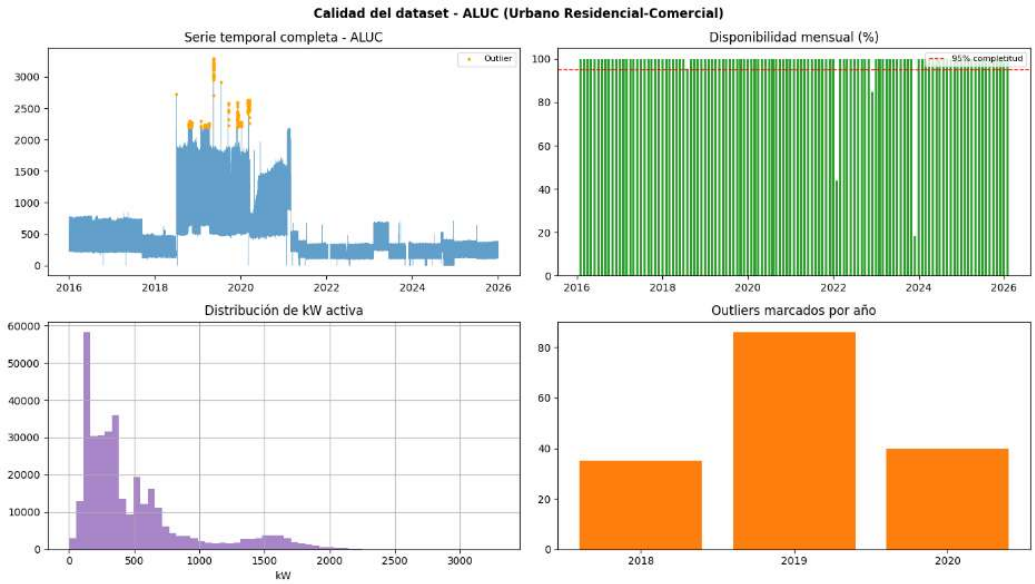

Nota: Completitud de: 98.69% | *CV (std/media): 0.884 , Los outliers se concentran en [2019, 2020], coincidiendo con [2019, 2020] — evidencia directa del régimen atípico 2019-2021.*

ALUC — Urbano Residencial-Comercial (CV = 0.884, el segundo más bajo)

Completitud 98.69%.

Solo 5 huecos grandes sin imputar — el valor más bajo de los 5.

161 outliers marcados — el segundo valor más bajo.

kW media (484.21) la segunda más alta de los 5.

Figuras 6

Calidad del Dataset ALUR

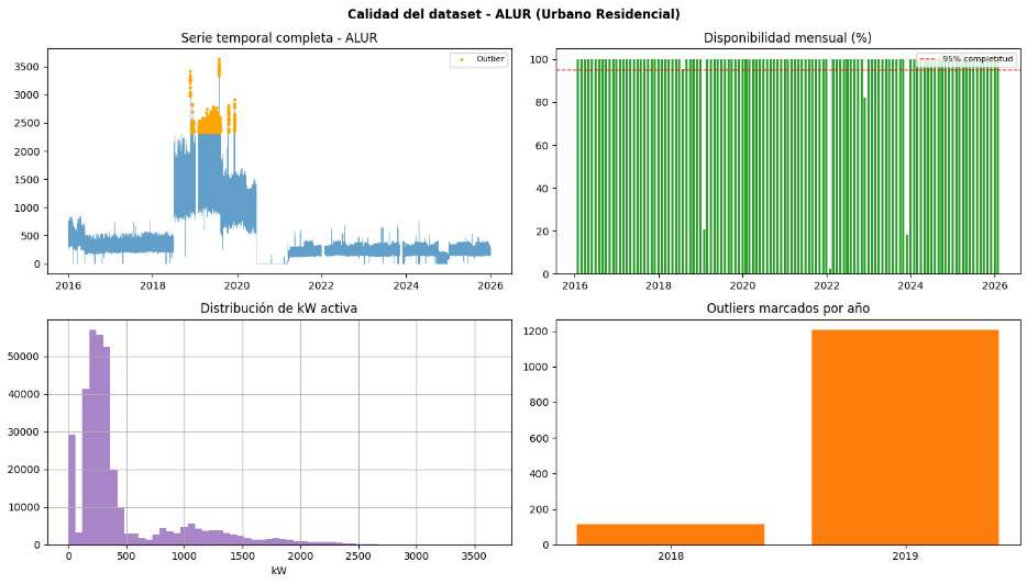

Nota: Completitud: 97.64% **|** *CV (std/media): 1.04, los outliers se concentran en [2019, 2018], coincidiendo con [2019]* **—** *evidencia directa del régimen atípico 2019-2021.*

ALUR **—** Urbano Residencial (CV = 1.043, el más alto de los 5 Alimentadores)

Completitud 97.64% — la segunda más baja de los 5.

8,501 huecos de comunicación **—** el segundo valor más alto.

1,319 outliers marcados **—** el segundo más alto (después de ALIN).

kW std (470.75) **supera** a la kW media (451.43).

Figuras 7

Calidad del Dataset ALRA

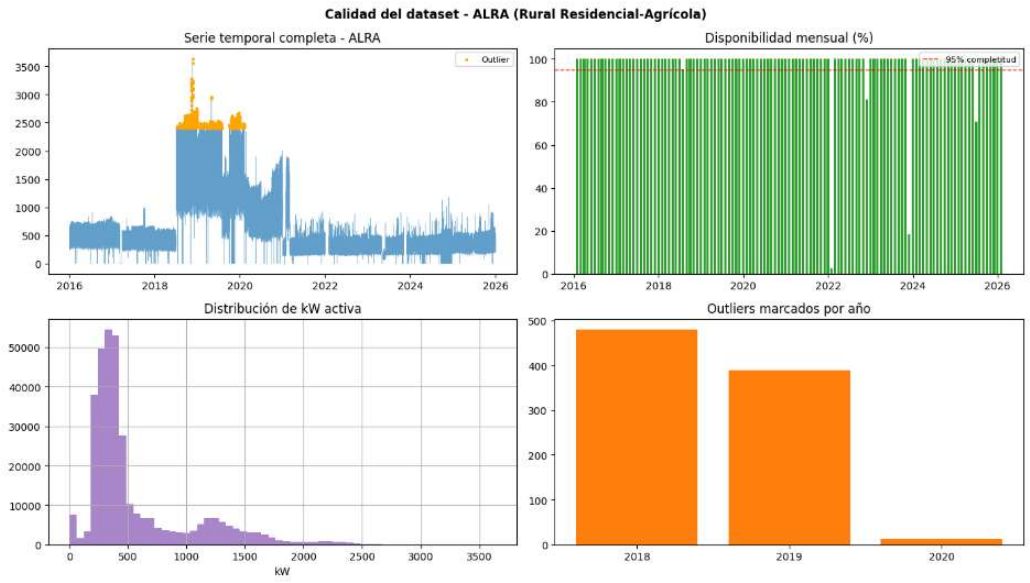

Nota: Completitud: 98.07% **|** *CV (std/media): 0.812, los outliers se concentran en [2019, 2018], coincidiendo con [2019]* **—** *evidencia directa del régimen atípico 2019-2021.*

Completitud 98.07%.

kW media (565.87) — la **más alta** de los 5 (para "rural" es alto, pero consistente con cargas agrícolas de bombeo/riego con demanda base considerable).

879 outliers marcados **—** moderado.

Figuras 8

Calidad del Dataset ALRG

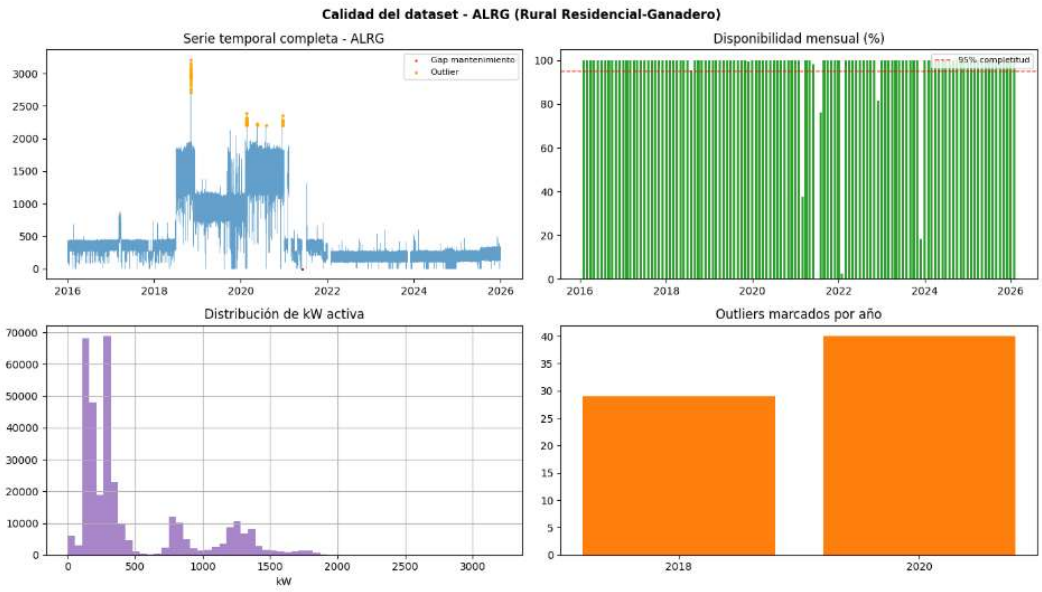

Nota: Completitud: 96.80% | CV (std/media): 0.933, los outliers se concentran en [2019, 2018], coincidiendo con [2019] — evidencia directa del régimen atípico 2019-2021.

Completitud 96.80% — la **más baja** de los 5.

11,243 huecos de comunicación y 9 huecos grandes sin imputar — ambos el valor **más alto** de los 5, por un margen amplio.

Solo 69 outliers marcados — el valor **más bajo** de los 5.

3.3. Diseño y configuración del modelo LSTM multivariable

El diseño del modelo pasó por cuatro versiones que fueron definidas desde el inicio, con ventana fija de 96 pasos(24h de historial) y con un horizonte de 4 pasos(1h).

Modelo v1: predice directamente la potencia activa absoluta a partir de una ventana de entrada de 672 pasos (siete días) y las 26 variables de contexto del preprocesamiento, generando un horizonte de predicción de 96 pasos (24 horas). Su arquitectura combina una capa convolucional causal (van den Oord et al., 2016) con tres

capas LSTM apiladas (128, 64 y 32 unidades), normalización por lotes (Ioffe & Szegedy, 2015) y dropout (Srivastava et al., 2014) entre ellas, y una capa densa final antes de la salida. Se entrenó con una función de pérdida Huber asimétrica (Huber, 1964) que penaliza más fuerte la subestimación que la sobreestimación de la demanda, decisión que responde a que, en un contexto de planificación de carga, subestimar la demanda futura suele ser operativamente más costoso que sobreestimarla.

Modelo v2: implemento un split por fechas absolutas en lugar de un split porcentual, de tal manera que implemento un LayerNormalization de entrada, detallado de la siguiente manera (train <= 2022, val = 2026, test (2024-2025).

Modelo v3: excluye 2019-2021, debido a que al momento de inspeccionar la data del 2019-2021 se encontró con un régimen de demanda muy distinto al usual, debido a los patrones de pandemia seguido de una activación atípica en algunos alimentadores, también se procedió a evaluar el modelo bajo dos condiciones: test limpio (excluyendo el periodo 2024 debido a los cortes de energía programados) y test limpio (con racionamiento) para de esta manera no sobre penalizar.

Modelo v4: reformula el problema: en lugar de predecir la demanda absoluta, aprende el residuo entre el valor real y la persistencia de hace 24 horas (lag-96). La idea detrás de esta reformulación es que la persistencia diaria ya es, por sí sola, un predictor razonablemente fuerte en series con estacionalidad diaria marcada, así que conviene que el modelo concentre su capacidad en aprender solo la corrección sobre ese punto de partida, en vez de reconstruir toda la señal desde cero. Trabaja sobre una ventana más corta (96 pasos, 24 horas).

La partición de los datos también difiere entre versiones. Mientras que v1 usa el split cronológico genérico definido en el preprocesamiento, v4 introduce una partición por régimen de demanda, motivada por un diagnóstico previo que detectó una anomalía

sostenida entre 2019 y 2021 en los cinco alimentadores, coincidente con la pandemia y una posterior activación de carga industrial, así como ventanas de racionamiento eléctrico durante 2024. Por eso, el conjunto de entrenamiento de v4 excluye 2019-2021 y se compone de 2016-2018, 2022 y el primer semestre de 2023; la validación corresponde al segundo semestre de 2023; y la prueba, al año 2024 completo, excluyendo explícitamente las ventanas de racionamiento detectadas para no penalizar al modelo por cortes de suministro ajenos a su capacidad predictiva.

3.4. Entrenamiento y ajuste de hiper-parámetros (entorno Kaggle GPU)

El entrenamiento de los cinco alimentadores (v1 a v4 / horizonte 1h) se trasladó de un entorno local sin GPU a Kaggle sobre GPU P100, dado el costo computacional de entrenar redes LSTM profundas sobre varios años de datos a resolución de 15 minutos.

El desarrollo pasó por versiones intermedias (v2 y v3) que no se documentan como arquitecturas independientes porque cumplieron una función exclusivamente diagnóstica: confirmaron la necesidad de particionar los datos por régimen en lugar de un split cronológico simple, conocimiento que se aplicó directamente en v4 sin repetir el entrenamiento completo de esas variantes, ahorrando cerca de 7.8 horas de cómputo en GPU.

Se usaron callbacks ModelCheckpoint , EarlyStopping, ReduceLROnPlateau, además se liberó explícitamente la sesión de Keras después de completar cada alimentador, para evitar que el grafo computacional de TensorFlow se acumulara en memoria de GPU a lo largo de las diez ejecuciones con una tasa inicial más conservadora (2×10^{-4}) y un tamaño de lote de 256 y un máximo de 300 épocas.

Se establecieron umbrales de MAPE diferenciados según el tipo de alimentador, en función de su coeficiente de variación: 8% para los alimentadores rurales, 9% para el

urbano-comercial, y 12% para el industrial y el urbano-residencial, estos dos últimos con mayor variabilidad estructural.

Tabla 5

Definición de Umbral Práctico y Teórico

Código	Descripción Alimentador	Umbral Práctico	Umbral Teórico	CV
ALIN	Industrial	12.0	N/A*	1.039
ALUC	Urbano Residencial-Comercial	9.0	5.0	0.884
ALUR	Urbano Residencial	12.0	5.0	1.043
ALRA	Rural Residencial-Agrícola	8.0	8.0	0.812
ALRG	Rural Residencial-Ganadero	8.0	8.0	0.933

Nota. Se detalla el umbral teorico y el umbral practico calculado en base a CV.

3.5. Refinamiento del modelo y variantes evaluadas

El descubrimiento más importante durante esta etapa es que v2 y v3 no mejoraron el desempeño con respecto a v1, estas correcciones fueron diseñadas explícitamente para resolver problemas específicos (COVID, racionamientos eléctricos, cambios en régimen de train y test).

Tabla 6

Comparación versiones MAPE (ALGR)

Versión	MAPE (ALRG)	R^2
v1 (línea base)	4.27%	0.9227
v2 (partición por fechas + LayerNorm)	13.96%	0.6238
v3 (régimen limpio + dual-input)	5.12%	0.8789
v4 (aprendizaje de residuos)	3.21%	0.9239

Nota. Muestra una comparación de versiones aplicadas al alimentador ALGR

Figuras 9

Comparación Versiones MAPE (ALRG)

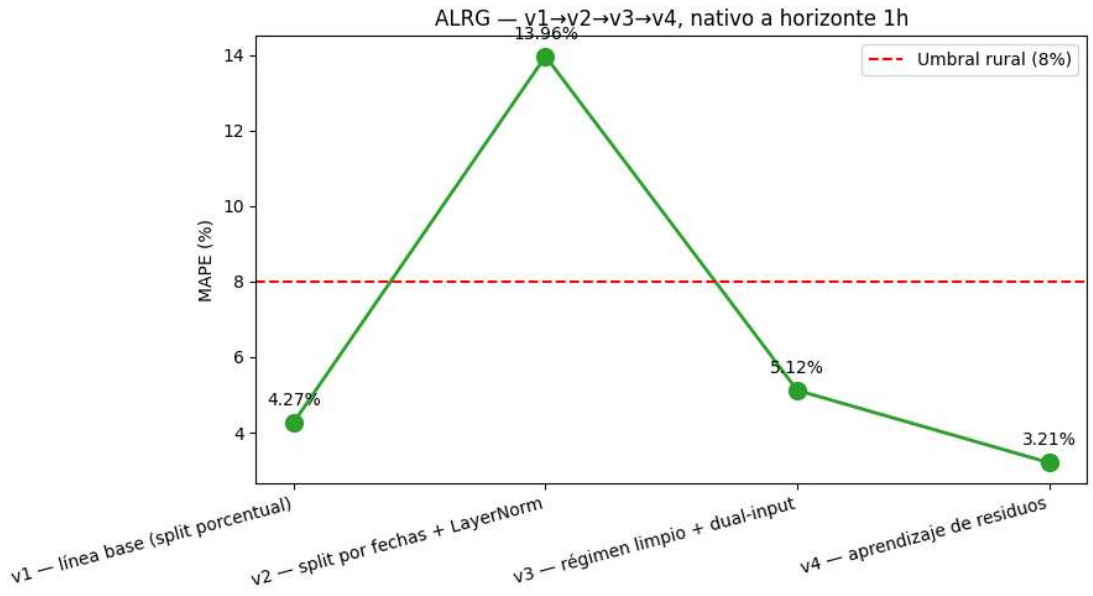

Nota: Comparativa del resultado de MAPE en todas las versiones generadas ALRG

Tabla 7

Comparación MAPE v1-v4 Modelo LSTM

Alimentador	MAPE v1	MAPE v4	Mejora (pp)	¿v4 cumple umbral práctico?
ALIN	6.042%	5.683%	+0.359	✓ (umbral 12%)
ALUC	3.526%	2.156%	+1.370	✓ (umbral 9%)
ALUR	3.746%	2.361%	+1.385	✓ (umbral 12%)
ALRA	4.867%	2.982%	+1.885	✓ (umbral 8%)
ALRG	5.198%	3.898%	+1.300	✓ (umbral 8%)

Nota. en esta tabla se evidencia la comparación de la métrica MAPE entre v1 y v4, y también verifica si cumple o no el umbral practico.

CAPITULO 4:

4. ANÁLISIS DE RESULTADOS

4.1. Pruebas de Concepto

Durante en desarrollo de los modelos, se ha presentado algunos escenarios que hemos considerado para que el desarrollo sea el adecuado.

Los archivos exportados por los medidores EEASA presentan **tres heterogeneidades críticas** que deben resolverse antes de entrenar cualquier modelo de aprendizaje profundo:

Tabla 8

Listado de Problemas Detectados

Problema detectado	Ejemplo real	Estrategia de solución
Medidor Tipo A: 17 variables trifásicas	ALRG	Suma de fases + extracción de derivadas
Medidor Tipo B: 5 variables básicas	ALUR0216.csv	Uso directo de kWh del int
Medidor Tipo C: 9 variables con frecuencia	ALRG-gap.csv	Columna Vll avg + reconstrucción
Timestamp perdido (mes en cero)	Archivo de gap de mantenimiento	Reconstrucción desde nombre de archivo
Formato de fecha diferente	DD/MM/YYYY vs YYYY-MM-DD	Parser multi-formato en cascada
Registros duplicados o faltantes	Cualquier archivo	Reindexado exacto a 15 min

Nota. Elaboración propia de autores.

Detección Automática del Tipo de Medidor, ya que un mismo alimentador puede tener archivos con esquemas de columnas completamente distintos según el

equipo instalado en cada período. Si el código asume siempre el mismo esquema, falla silenciosamente al procesar archivos con otro formato.

La detección automática por **intersección de conjuntos de columnas** es robusta ante columnas adicionales no registradas y permite extender el sistema con nuevos tipos de medidor simplemente agregando una entrada al diccionario.

Parsear Estándar: El Problema del Timestamp en Archivos EEASA, se detectaron **3 casos de timestamp** distintos en los archivos reales:

Tabla 9

Lista de Errores de TimeStamp

Caso	Descripción	Ejemplo	Solución
Caso 1	Formato día/mes/año con hora	01/04/2020 00:00:00	Parseo con formato exacto
Caso 2	Formato año-mes-día con milisegundos	01/02/2016 00:15:00.000	Parseo con formato con µs
Caso 3	Columna numérica = 0 (gap mantenimiento)	0.0 en toda la columna	Reconstrucción desde nombre de archivo

Nota. Elaboración propia de los autores.

Re-indexación, Imputación y Control de Calidad: Aunque la granularidad nominal es de 15 minutos, los archivos reales tienen:

Pasos faltantes (pérdida de comunicación con el medidor)

Pasos duplicados (sincronización incorrecta del reloj)

Saltos temporales en los gaps de mantenimiento

El reindexado genera un **índice perfecto sin gaps** desde el primer hasta el último timestamp, con NaN donde falta información. La imputación por interpolación lineal solo se aplica a huecos ≤ 2 horas (operativamente despreciables). Los huecos mayores se dejan como NaN y se excluyen del entrenamiento para no fabricar datos falsos.

Visualización de Calidad del Dataset: Esta visualización es el EDA principal del proyecto. Permite identificar de un vistazo:

Dónde están los gaps y outliers a lo largo de 10 años de datos

Si la distribución de demanda es unimodal o bimodal

Cómo varía el perfil diario entre días laborables y fin de semana

Justificación de las 26 Variables: El modelo LSTM no solo recibe la señal de kW activa — recibe también variables de contexto que permiten distinguir patrones según el momento del día, el día de la semana, y el comportamiento reciente de la demanda. Cada grupo de features tiene su justificación:

Tabla 10

Listado de variables definidas

Grupo	Variables	Justificación
Eléctrica	kw_activa, kvar_reactiva, fp	Señal objetivo + contexto de carga reactiva
Cíclica temporal	sin/cos de hora, día, mes, semana	Encoding sin/cos evita discontinuidades en medianoche y domingo
Calendario binaria	fin_semana, lunes, viernes, feriado	El ALRG rural tiene perfiles claramente distintos en días especiales
Lags	t-1h, t-2h, t-24h, t-48h, t-7días	El valor de ayer a la misma hora es el predictor más fuerte para STLF
Rolling 24h	media, std, max, min, rango	Contexto del nivel de actividad reciente del alimentador

Nota. Se detalla las variables definidas como feature.

Aprendizaje de Residuos: El análisis de residuos reveló el hallazgo definitivo:

El residuo promedio por paso (y_real − persistencia) tiene media ≈ 0 y std ≈ 30 kW

El rango de residuos es mucho más pequeño que el de kW absolutos (170±40 kW)

Si el LSTM predice Δ = 0, el resultado es la persistencia pura (MAPE = 7.01%)

El modelo solo necesita aprender **cuánto corregir**, no **el valor absoluto**

Formulación Matemática del Modelo v4

Target reformulado:

$\hat{y}(t+1, \ldots, t+96) = p(t+1, \ldots, t+96) + \Delta\hat{}(t+1, \ldots, t+96)$ donde:

$p(t+k) = y(t+k-96)$ — persistencia pura (mismo momento, día anterior)

$\Delta\hat{}(t+k)$ — corrección aprendida por el LSTM

El modelo LSTM v4 tuvo un proceso de 3.5 horas, las decisiones claves como son horizonte de 1h, entrenamiento limpio y regularización reforzada para ALIN se validaron en CPU para una muestra reducida y así no invertir tiempo de cómputo.

4.2. Análisis de Resultados

Al realizar la ejecución de la comparación de los modelos LSTM v1, v4, podemos generar el siguiente resultado de MAPE, RMSE, MAE por cada alimentador, como también el tiempo de la ejecución de cada alimentador.

Tabla 11

Comparación LSTM v1, v4

Alimentador	Descripción	Umbral Práctico	Umbral Teórico	MAPE V1 (%)	MAPE V4 (%)
ALIN	Industrial	12.0%	N/A	8,00%	5,68%
ALUC	Urbano Residencial-Comercial	9.0%	5.0%	2,99%	2,16%
ALUR	Urbano Residencial	12.0%	5.0%	4,32%	2,36%
ALRA	Rural Residencial-Agrícola	8.0%	8.0%	4,23%	2,98%
ALRG	Rural Residencial-Ganadero	8.0%	8.0%	4,49%	3,90%

Nota. Tabla comparativa de LSTM v1 – v4

Figuras 10

Comparación Alimentador LSTM V1 vs V4

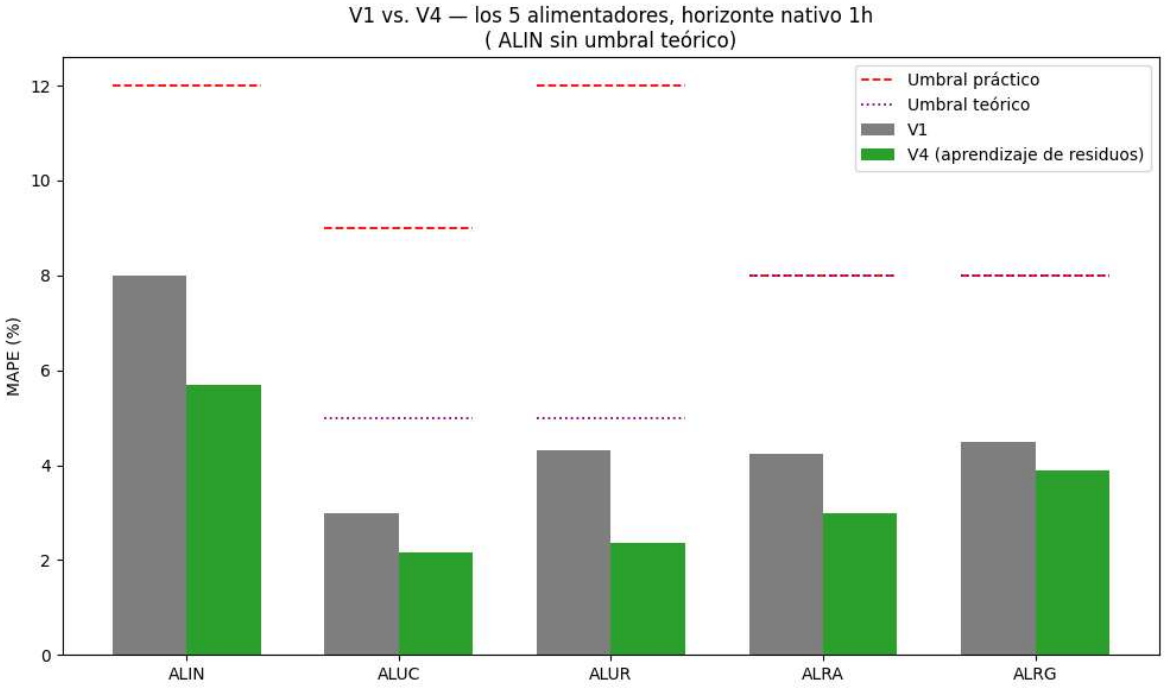

Nota: Comparativa del LSTM de la v1 vs v4 con el umbral teórico y práctico.

Donde el MAPE genera la precisión de los modelos, para lo que el modelo v4, dispone del porcentaje de error menor a comparación del v1, en cada alimentador tenemos reducción.

El modelo v4 es el más exitoso en todos los escenarios planteados ya que cumple con los umbrales de error, mejores ajustes ($R^2 > 0,89$).

4.2.1. Comparación con métodos clásicos de pronóstico

Se ha planteado el uso de los métodos clásicos de pronóstico como: ARIMA, medias móviles y regresión lineal, donde:

ARIMA (AutoRegressive Integrated Moving Average), es un método de predicción de series temporales, son métodos estocásticos, basados en la historia de una serie de tiempo, este se basa en la combinación de tres componentes, para realizar la transformación de datos a pronósticos precisos:

AR (AutoRegressive –p): relación lineal entre observación actual y número de valores pasados.

I (Integrated - d): diferenciación de datos, para lograr la media y varianza, eliminando tendencias y patrones no deseados.

MA (Moving Average - q): relación entre observación actual y errores residuales de predicciones pasadas, permitiendo el refinamiento de la precisión.

Medias Móviles (Moving Averages): este método es un modelo muy utilizado en análisis temporales, es un cálculo que suaviza los datos mediante el promedio, no es necesario revisar la historia, el modelo toma un período de tiempo específico, y calcula el promedio.

Regresión Lineal: este modelo permite establecer una relación entre variable dependiente y una independiente, en este caso, la dependiente es la demanda eléctrica y la independiente: clima, hora, feriado).

Se ha ejecutó los 3 modelos (ARIMA; Medias móviles, persistencia y regresión lineal), para los cinco alimentadores. Los mismos que se evaluaron bajo el mismo horizonte de 1 hora y con la misma partición de train/val/test donde tenemos los siguientes resultados:

Tabla 12

Comparativo resultados con Otros Modelos de Predicción

Modelos Predictivos	ALIN	ALUC	ALUR	ALRA	ALRG
LSTM (V4)	**5.683%**	**2.156%**	**2.361%**	**2.982%**	**3.898%**
Regresión Lineal	10.496%	5.392%	4.519%	6.229%	7.937%
ARIMA	7.283%	6.426%	6.244%	9.456%	8.068%
Media Móvil	10.669%	13.474%	9.401%	11.414%	11.552%

Nota. Elaboración propia de los autores

Figuras 11

Comparativa Resultado Modelos Alimentados ALIN

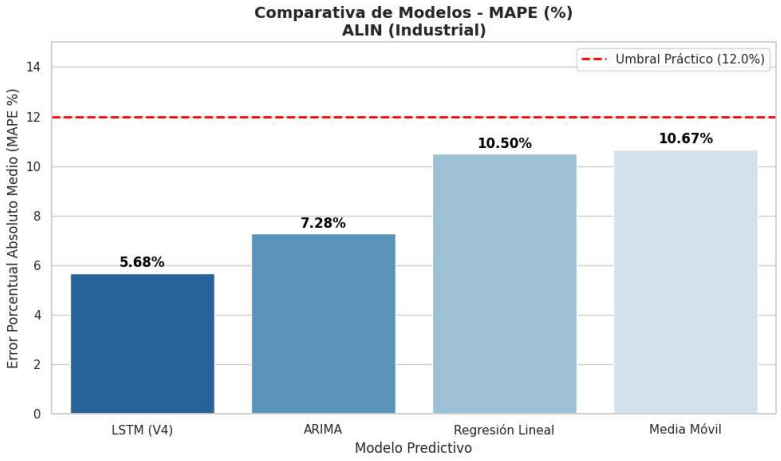

Nota: Comparativa del Alimentador ALIN de LSTM vs modelos clásicos.

Figuras 12

Comparativa Resultado Modelos Alimentados ALUC

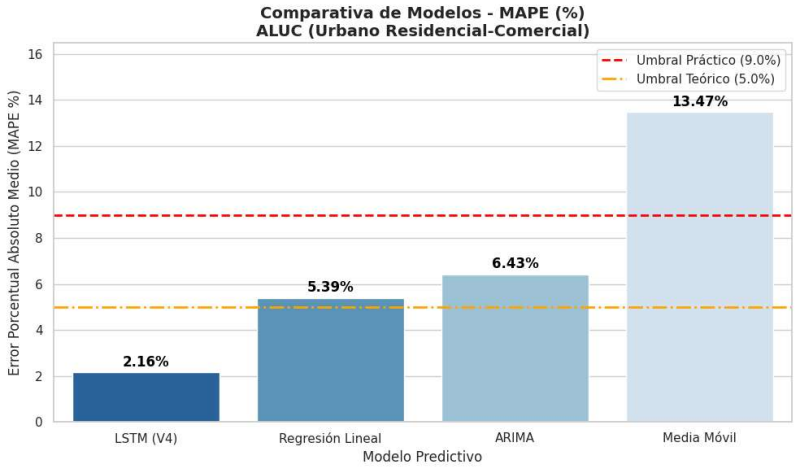

Nota: Comparativa del Alimentador ALUC de LSTM vs modelos clásicos.

Figuras 13

Comparativa Resultado Modelos Alimentados ALUR

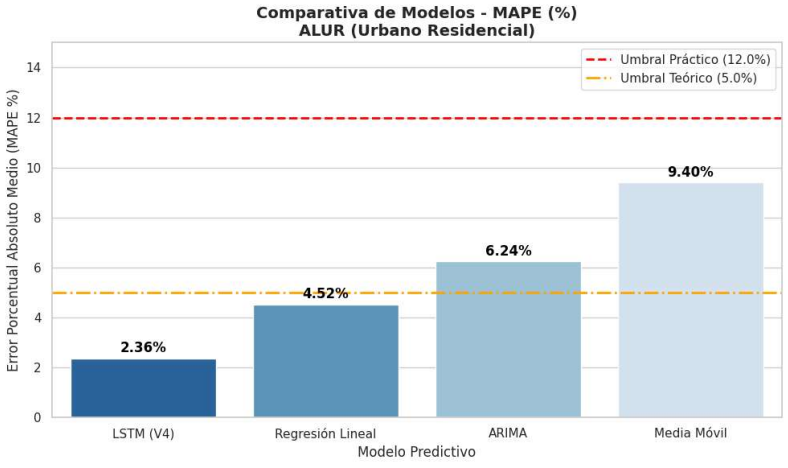

Nota: Comparativa del Alimentador ALUR de LSTM vs modelos clásicos.

Figuras 14

Comparativa Resultado Modelos Alimentados ALRA

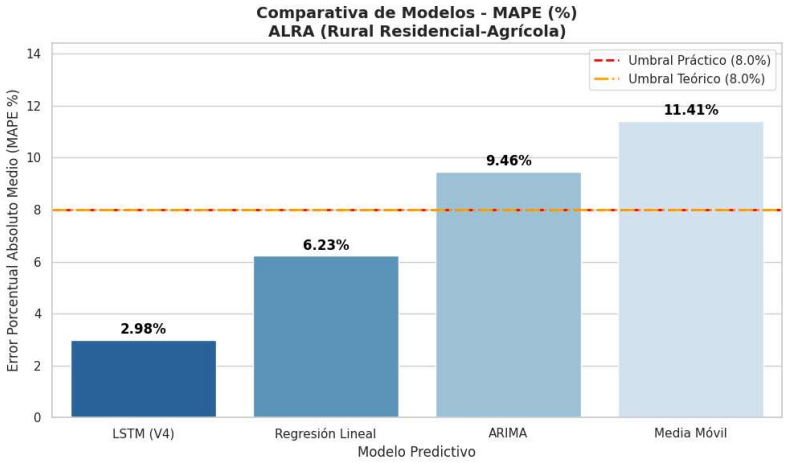

Nota: Comparativa del Alimentador ALRA de LSTM vs modelos clásicos.

Figuras 15

Comparativa Resultado Modelos Alimentados ALRG

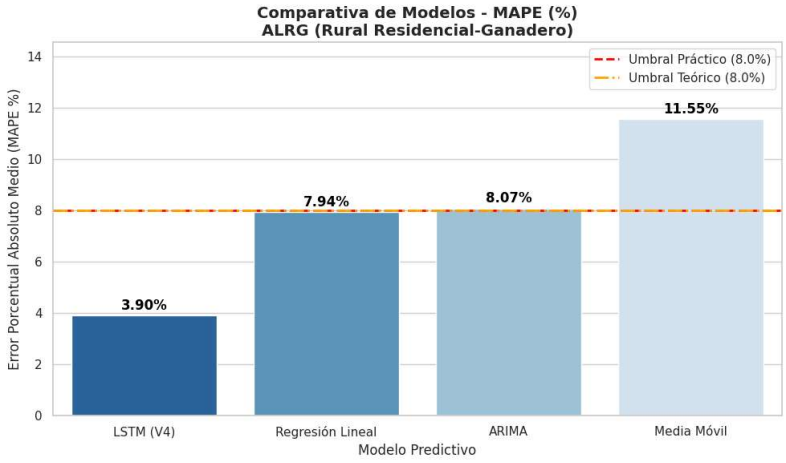

Nota: Comparativa del Alimentador ALRG de LSTM vs modelos clásicos.

Donde se visualiza que en todos los alimentadores el resultado de LSTM es muy inferior al resto de los modelos de estudio.

Tabla 13

Cumplimiento de Modelos Predictivos por Alimentador

Modelos Predictivos	ALIN (< 12%)	ALUC (< 9%)	ALUR (< 12%)	ALRA (< 8%)	ALRG (< 8%)	Tasa de Éxito
LSTM (V4)	✅ Sí	✅ Sí	✅ Sí	✅ Sí	✅ Sí	**5 de 5 (100%)**
Regresión Lineal	✅ Sí	✅ Sí	✅ Sí	✅ Sí	✅ Sí	**5 de 5 (100%)**
ARIMA	✅ Sí	✅ Sí	✅ Sí	❌ No	❌ No	**3 de 5 (60%)**
Media Móvil	✅ Sí	❌ No	✅ Sí	❌ No	❌ No	**2 de 5 (40%)**

Nota. Detalle del cumplimiento del umbral de aceptación por alimentador.

Donde se puede observar los resultados de (MAPE), el modelo LSTM (v4) fue el que tuvo menor MAPE para los cincos alimentadores. El modelo de regresión lineal tuvo el segundo lugar, Media móvil y persistencia fueron los modelos más débiles.

Figuras 16

Tasa de cumplimiento entre modelos Predictivos

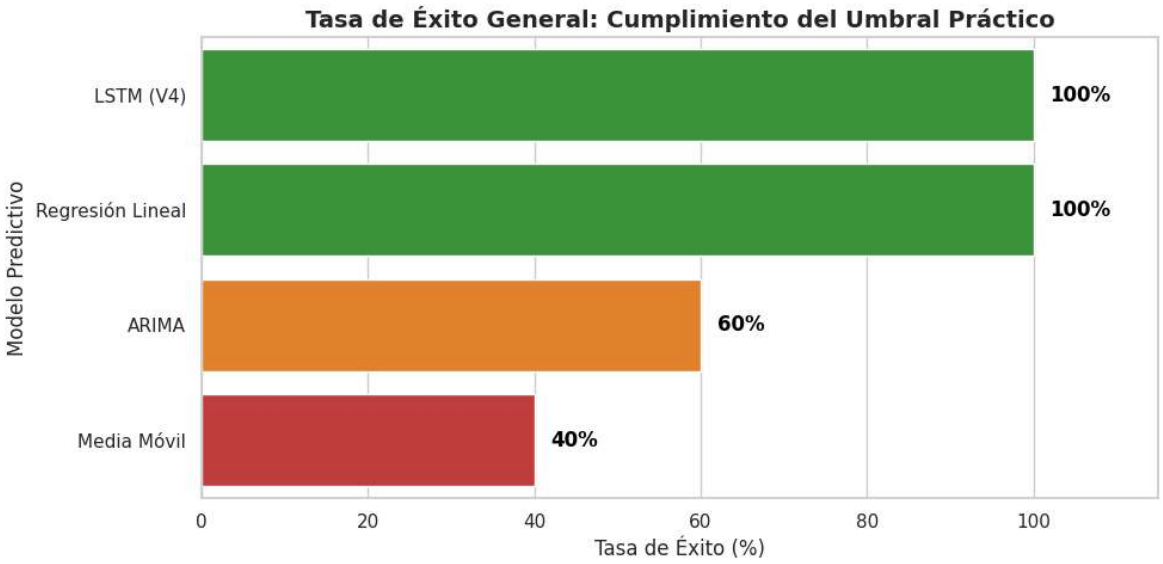

Nota: Cumplimiento del Umbral Práctico entre todos los modelos clásicos y LTSM

Las LSTM están enfocadas para procesamiento durante períodos extensos y pueden ser adaptables a variaciones abruptas, las LSTM son más flexibles y adaptables a nuevas realidades, mientras que una regresión lineal es rígida.

Las LSTM, tiene mayor capacidad para extraer características de datos, lo que significa reducción en el trabajo, mientras que regresión línea requiere intervenciones manuales.

Por lo que, la LSTM es robusta ante la complejidad del futuro.

4.2.2. Discusión de resultados por tipo de alimentador

Con respecto al perfil de demanda que tenemos en los alimentadores, Rural, Industrial, Urbano, podemos mencionar lo siguiente:

Perfil Urbano (ALUC, ALUR): se puede observar que el modelo LSTM v4, es el más eficaz y robusto, ya que su comportamiento fue los óptimos en MAPE, 5.68% (ALUR) y 2.36% (ALUC). Los consumos urbanos son más predecibles y constantes, para esto el modelo v4 consigue capturar la rutina residencial con mayor confianza, demostrando que existen patrones de demanda consistentes al incorporar codificaciones cíclicas temporales y feriados, logro aprender con alta precisión (R^2 >0.98 para ambos alimentadores).

Perfil Rural (ALRA, ALRG): Fueron aceptados con algunas consideraciones que se debe tomar en cuenta, el alimentador ALRA tuvo un buen MAPE 2.982% vs umbral 8% y ALRG (MAPE 3.90% vs umbral 8%), sin embargo, con una mayor degradación a nivel proporcional frente al racionamiento y menor R^2 para ALRG (0.89), es decir, el modelo puede predecir la demanda rural, pero en el ganadero existe una variabilidad no capturada, probablemente debido a patrones de consumo agrícola.

Perfil Industrial: para este sector podemos evidenciar que el comportamiento (MAPE =5.683%) a pesar de presentar el umbral más permisivo (12%), pero también con mayor dificultar para el modelo LSTM. en la interpretación este sector es más volátil por diferentes factores propios de la industria, evidenciando problemas de multicolinealidad y la necesidad de realizar una regulación reforzada.

4.2.3. Resultados de Predicción

Se ha ejecutado la predicción por cada alimentador para visualizar la diferencia que se encontró entre la v1 y v4, donde podemos visualizar que el v4 está muy cercana al valor real que se realizó la comparación, con esto, dejamos demostrado que el modelo LSTM es más eficaz para la predicción del consumo eléctrico.

Figuras 17

Ejemplo predicción V1 vs V4 para ALIN

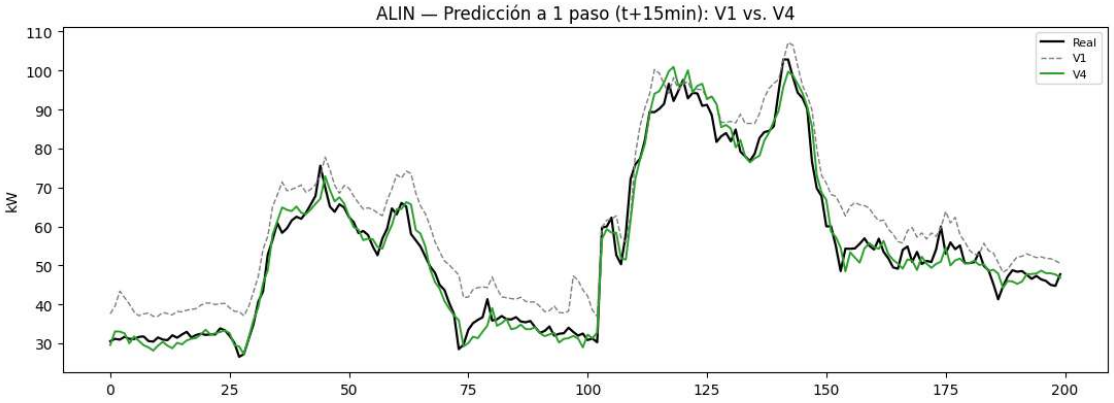

Nota: Predicción Ejemplo del Alimentador ALIN vs V1 y v4.

Figuras 18

Ejemplo predicción V1 vs V4 para ALUC

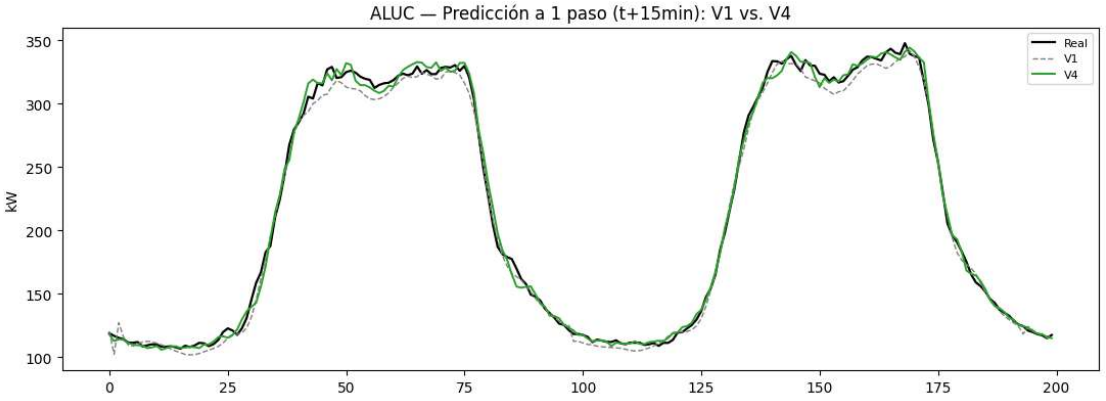

Nota: Predicción Ejemplo del Alimentador ALUC vs V1 y v4

Figuras 19

Ejemplo predicción V1 vs V4 para ALUR

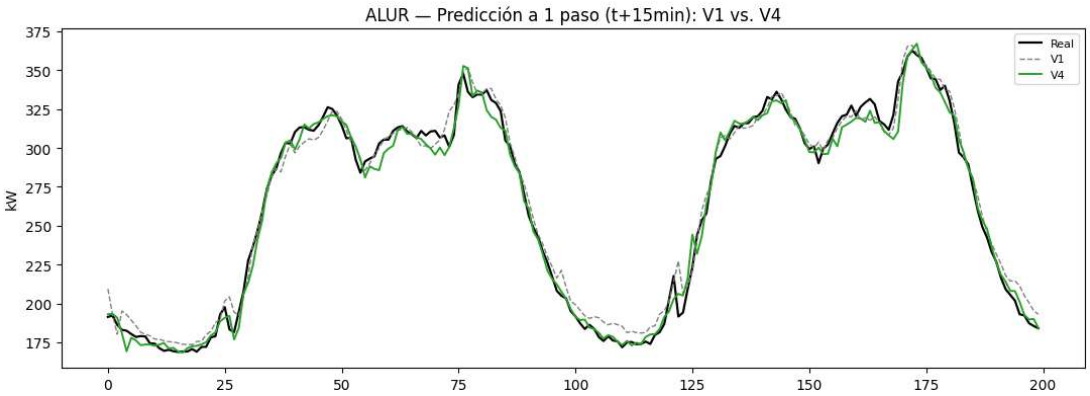

Nota: Predicción Ejemplo del Alimentador ALUR vs V1 y v4

Figuras 20

Ejemplo predicción V1 vs V4 para ALRA

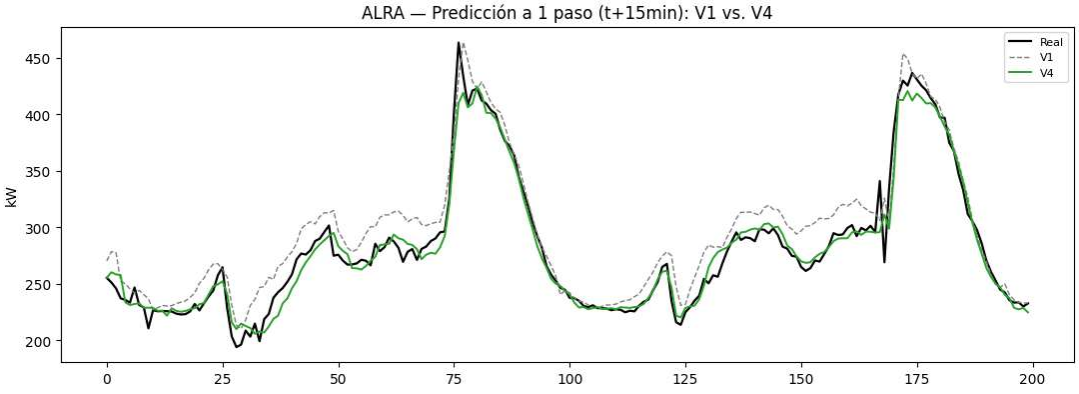

Nota: Predicción Ejemplo del Alimentador ALRA vs V1 y v4

Figuras 21

Ejemplo predicción V1 vs V4 para ALRG

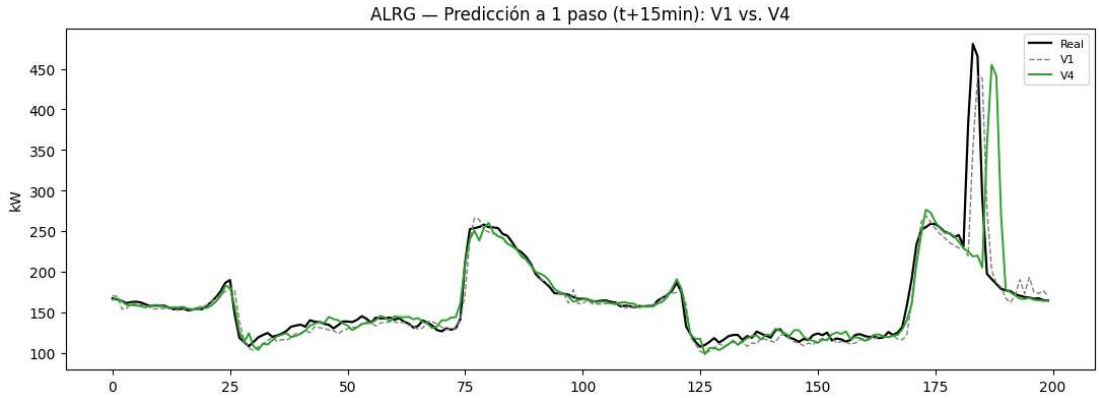

Nota: Predicción Ejemplo del Alimentador ALRG vs V1 y v4

Adicionalmente se ha preparado el dashboard, donde podemos visualizar el valor entre loa real vs la predicción del modelo LSTM.

Figuras 22

Dashboard LSTM por Alimentador

Nota: Dashboard para visualizar el pronóstico del modelo por Alimentador

Al seleccionar el Alimentador podemos visualizar métricas de MAPE y comparación de métricas.

Figuras 23

Dashboard, visualización metricas por alimentador

Nota: Dashboard que se visualiza todas las métricas generads por el Alimentador

A continuación, se puede visualizar la gráfica del valor real vs la predicción, sobre el mismo horizonte de corte de 1 hora (con intervalos de 15 minutos, que da 4 pasos), se dispone de 500 ventanas de visualización por alimentador, tanto para el modelo base v1 como el final v4, claramente se visualiza la diferencia entre lo real y la predicción.

Figuras 24

Dashboard comparación real vs predicción

Nota: *Dashboard para visualizar el pronóstico entre lo real y la predicción por Alimentador*

CAPITULO 5:

5. CONCLUSIONES Y RECOMENDACIONES

5.1. Conclusiones generales

El proyecto demostró que un modelo LSTM multivariable, entrenado con datos reales de medición de los cinco alimentadores de distribución eléctrica de la EEASA y evaluados en un horizonte de una hora (4 pasos de 15 minutos, ventana de 24 horas =96 pasos), pronostica el consumo eléctrico de corto plazo a nivel de alimentador con mayor precisión que los métodos clásicos de pronóstico (ARIMA, regresión lineal y medias móviles), cumpliendo los umbrales de aceptación definidos para los cinco alimentadores evaluados.

La última arquitectura (V4) implementada, considera al objetivo de aprendizaje como un residuo respecto a una línea base de persistencia (Δ = valor real − persistencia), en lugar de predecir directamente los kW absolutos. Este esquema se utiliza para los cinco alimentadores de distribución, lo que mostró una mejora medible respecto a la configuración V1 estándar, por lo que fue adoptada para su implementación y evaluación bajo los umbrales prácticos y bajo los umbrales teóricos (urbano, rural) considerando que ALIN es un alimentador industrial, no tiene categoría teórica definida.

5.2. Conclusiones específicas

5.2.1. Análisis del cumplimiento de los objetivos de la investigación

Se desarrolló de un proceso iterativo (v1→v2→v3→v4), documentado en un alimentador representativo (ALRG) y luego fue aplicado con 2 arquitecturas (v1 y v4) de mejor rendimiento a los cuatro alimentadores restantes, evaluado con las cuatro métricas (MAPE, RMSE, MAE y R^2) para los cinco alimentadores

El proyecto abarca datos del periodo 2016-2025 con su análisis de calidad de datos confirmando un régimen de demanda estadísticamente atípico durante 2019–2021

en los cinco alimentadores, y documentó las ventanas de racionamiento de 2024 explícitamente como una condición de evaluación separada.

El sistema de features creado integra los tipos de datos más importantes que son: variables de calendario (día de la semana, fin de semana, lunes a viernes), feriados ecuatorianos (holidays), estadísticas derivadas (5 lags de demanda y 5 estadísticos móviles de 24h), por lo que se obtuvo un total de 26 variables de una forma sistemática para los cinco alimentadores.

La comparación de los modelos estadísticos tradicionales y el modelo LSTM, se lo realizó mediante un protocolo de evaluación alineado con el mismo horizonte, donde la arquitectura LSTM V4 obtiene el menor MAPE en los cinco alimentadores (Capítulo 5 literal 5.3), seguido consistentemente por regresión lineal en segundo lugar, luego ARIMA y media móvil; lo que refleja la fuerte relación lineal entre la demanda y las variables de calendario/horario, incluso antes de aplicar la capacidad no lineal del LSTM.

El modelo LSTM implementado, confirmó que puede aprender patrones complejos ya que el consumo eléctrico puede comportarse de forma errática, está enfocado para un procesamiento durante períodos extensos y puede ser adaptable a variaciones abruptas, más flexibles y adaptables a nuevas realidades.

5.2.2. Contribución a la gestión empresarial

La mayor ventaja del modelo LSTM sobre la regresión lineal (utilizada en la EEASA) es precisamente donde la demanda se comporta de forma menos lineal, como ejemplos el alimentador industrial (ALIN) y los alimentadores urbanos siendo los más volátiles, es decir, el valor operativo del modelo escala justo en los alimentadores donde los métodos clásicos son más débiles.

Un pronóstico confiable a 1 hora le da a la EEASA una base para decisiones operativas de corto plazo: anticipar picos de demanda, planificar de forma proactiva

ventanas de mantenimiento en los alimentadores, y reducir márgenes de reserva innecesariamente amplios.

La arquitectura única aplicada de forma uniforme a los cinco alimentadores es más sencilla de mantener, reentrenar y eventualmente extender a alimentadores adicionales para la EEASA, sin tener que crear una configuración a medida cada vez.

5.2.3. Contribución a nivel académico

La investigación realizada aporta una evidencia no solo teórica sino también empírica ya que el aprendizaje sobre una línea base con respecto a la persistencia mejora sistemáticamente con respecto a un modelo LSTM que preside una demanda absoluta de manera directa. La mejora alcanzada de v4 vs v1 fue entre 0.59 y 2.32 puntos porcentuales de MAPE para los cinco alimentadores que fueron evaluados.

Por régimen de demanda este modelo también aporta una metodología de partición temporal, la cual se justifica con una verificación estadística la cual demuestra sus propios límites: al momento de aplicar para los cinco alimentadores se pudo evidenciar cuantitativamente que las decisiones experimentales, partición temporal y el reajuste del problema a un target de residuos, contaron con un impacto mayor en el desempeño final. Como aporte metodológico importante fue documentar ese matiz y no solo omitirlo, ya que este sirve como una estrategia futura de partición a series lo cual requiere una validación por serie individual.

El coeficiente de variación (CV) es el impulsor de la inestabilidad del MAPE entre alimentadores con un error absoluto (RMSE/MAE) donde: el CV va de 0.812 (ALRA) a 1.043 (ALUR) entre los cinco alimentadores, y el umbral práctico que se calibra en esta investigación (en lugar de un único corte fijo urbano/rural) propone no penalizar injustamente a los alimentadores inherentemente más volátiles, manteniendo al mismo tiempo un estándar exigente para los alimentadores más estables.

El alimentador industrial ALIN se obtuvo con un MAPE del 5.683%, en lugar de tomar arbitrariamente el umbral de una categoría existente o dejarlo sin ningún estándar cuantitativo de aceptación, este proyecto fundamenta el umbral de ALIN en la volatilidad empírica propia del alimentador (CV = 1.039, el segundo más alto de los cinco, prácticamente idéntico al 1.043 de ALUR). Esto se convierte en una documentada inestabilidad del MAPE frente a series con alta dispersión relativa (Hyndman & Koehler, 2006) en una regla reproducible y basada en datos, se debería tomar en cuenta este criterio para cualquier alimentador futuro ya se industrial o de otro tipo que pueda recibir un umbral defendible de la misma manera.

5.2.4. Contribución a nivel personal

Este proyecto represento nuestra primera experiencia diseñando un sistema de machine Learning, desde datos crudos y desordenados hasta implementar una herramienta que otra persona pueda usar. Antes de este proyecto nuestra experiencia con las redes neuronales era simplemente académica, es decir ejercicios con dataset limpios donde los retos solo era la implementación del modelo. En este caso nuestro mayor desafío fueron los datos, gran parte del tiempo que se invirtió fue en resolver los problemas con respecto a la calidad de los datos, para que así nuestro modelo pueda ser más preciso y mejor el tiempo de procesamiento. Ya que teníamos fechas en cero debido a una falla de comunicación con el medidor. Esto nos enseñó que el preprocesamiento de los datos no es el paso previo al trabajo interesando, sino la mayor parte del trabajo, es decir tener una data limpia para poder emplear un modelo.

La parte que marcó a nivel personal no fue la técnica sino la metodológica, ya que se verificar estadísticamente anomalías de 2019-2021, siendo un régimen de demanda objetivamente distinto y presente en los cinco alimentadores por igual. Aprendimos que la rigurosidad no es solo aplicar bien una técnica, sino también estar dispuesto a cuestionar

y a exponer las propias decisiones de diseño cuando los datos no las respaldan, incluso cuando eso significa admitir un resultado más limitado en su alcance temporal de lo que se preferido presentar.

El desarrollo del proyecto permitió adquirir experiencia práctica en el diseño de pipelines reproducibles de aprendizaje profundo, en el manejo de datos operativos reales con sus inconsistencias propias (formatos heterogéneos, valores atípicos, esquemas de medición distintos), y en la evaluación crítica de modelos bajo criterios de aceptación definidos previamente.

5.3. Limitaciones a la Investigación

Los eventos atípicos fueron excluidos del conjunto de prueba. La metodología de división por régimen excluyó deliberadamente el período 2019-2021 y las ventanas de racionamiento de 2024, tanto del entrenamiento como de la evaluación. Si bien esto es metodológicamente válido para medir el rendimiento en condiciones normales, limita la evidencia sobre cómo se comportaría el modelo ante eventos anómalos futuros (racionamiento, regímenes de demanda atípicos).

El modelo se entrenó sin variables exógenas. El entrenamiento se basó exclusivamente en la serie histórica de demanda y variables derivadas de ella (como calendario, lags y estadísticas móviles). No se incluyeron variables climáticas (temperatura, radiación solar) ni económicas, a pesar de que la literatura sobre pronóstico de carga sugiere que estas variables suelen mejorar el rendimiento, especialmente en alimentadores.

El alimentador industrial ALIN cumple su umbral práctico (5.683% de MAPE frente a un umbral de 12%), pero es el único alimentador sin categoría teórica y muestra el R^2 más débil en relación con su propio margen de error (0.9381). En trabajos futuros se debe probar un enfoque de regularización reforzada o realizar un estudio con diferentes

features a las implementadas en esta investigación, ya que el error residual del alimentador parece responder a una característica propia de su proceso de demanda, y no a un parámetro ajustable del modelo.

Finalmente, el estudio se limita a cinco alimentadores de tres cantones de Tungurahua, por lo que la generalización de los resultados a otras provincias o tipos de red debe validarse en trabajos posteriores.

5.4. Recomendaciones

Evaluar una posible extensión del modelo para horizontes intermedios (6 y 12 horas), para ampliar el uso operativo más allá de 1 hora

Si se dispone de datos correspondientes a temperatura y precipitación disponibles para la región de Tungurahua, sería útil incluir explícitamente estas variables meteorológicas. Actualmente, el modelo solo toma en cuenta la estacionalidad usando códigos de calendario. Se recomienda a la EEASA establecer un proceso de reentrenamiento periódico del modelo (por ejemplo, trimestral) que incorpore nuevas mediciones, con el fin de mantener la precisión del pronóstico ante cambios sustanciales en el consumo, como la inclusión de generación distribuida o vehículos eléctricos mencionada en el Capítulo 1. Además, se recomienda extender el estudio a un número mayor de alimentadores y provincias, así como evaluar mecanismos de atención y arquitecturas Transformer (sección 3.2.3) como alternativa o complemento al modelo LSTM, dado su desempeño reportado en la literatura reciente sobre pronóstico de demanda eléctrica.

Evaluar el comportamiento del modelo bajo condiciones de racionamiento o regímenes atípicos, como un análisis a futuro, ya que la investigación excluyó intencionalmente estas condiciones de la comparación en ventana limpia y cuantificar el desempeño en ellas quedó identificado como una brecha, no resuelta. Además de evaluar

mecanismos de atención o arquitecturas Transformer (según lo discutido en el estado del arte) como complemento o alternativa al LSTM, dado su desempeño reportado en la literatura reciente de pronóstico de carga.

Bibliografía

Alfares, H. K., & Nazeeruddin, M. (2002). Electric load forecasting: Literature survey and classification of methods. *International Journal of Systems Science*, *33*(1), 23–34. https://doi.org/10.1080/00207720110067421

Bahdanau, D., Cho, K., & Bengio, Y. (2015). Neural machine translation by jointly learning to align and translate. En *Proceedings of the 3rd International Conference on Learning Representations (ICLR 2015)*. https://arxiv.org/abs/1409.0473

Bergmeir, C., & Benítez, J. M. (2012). On the use of cross-validation for time series predictor evaluation. *Information Sciences*, *191*, 192–213. https://doi.org/10.1016/j.ins.2011.12.028

Box, G. E. P., & Jenkins, G. M. (1970). *Time series analysis: Forecasting and control*. Holden-Day.

Browell, J., Fasiolo, M., & Nambiar, M. (2022). Probabilistic load forecasting for the low voltage network: Forecast fusion and daily peaks. *IEEE Transactions on Smart Grid*, *13*(3), 1738–1748. https://doi.org/10.1109/TSG.2022.3150101

Centro Nacional de Control de Energía [CENACE]. (2024). *Informe anual 2024*. Operador Nacional de Electricidad CENACE. https://www.cenace.gob.ec/wp-content/uploads/downloads/2025/04/Informe-Anual-CENACE-2024-vf-1-88_c.pdf

Dai, S., Meng, F., Dai, H., Wang, Q., & Chen, X. (2021). *Electrical peak demand forecasting: A review*. arXiv preprint arXiv:2108.01393. https://arxiv.org/abs/2108.01393