

Analysis of the SARIMA Method for Short-Term Electricity Demand Forecasting in Peru's Interconnected Electricity System

Juan C. Quispe¹; Michael Huaman²; José Pauyac³

^{1,2,3} Universidad Tecnológica del Perú, Perú

C21675@utp.edu.pe, u19209764@utp.edu.pe, u19212892@utp.edu.pe

Abstract— This work evaluates the performance of the SARIMA model in forecasting short-term (daily) electricity demand in the Peruvian electricity system, highlighting its ability to capture seasonal patterns and intraday variations inherent in load behavior. By incorporating autoregressive, differentiation, and seasonal components, the model adequately reproduces daily fluctuations, generating estimates that are consistent and coherent with the historical dynamics of the series. Likewise, the results demonstrate the robustness, interpretability, and computational efficiency of the proposed approach, making it a competitive alternative to more complex methods. Thus, the SARIMA model is positioned as a competitive tool for operational planning and short-term decision-making processes within electric power systems.

Keywords—*Demand, forecast, SARIMA, Short-term.*

Análisis del Método SARIMA para el Pronóstico de Demanda Eléctrica a Corto Plazo del Sistema Eléctrico Interconectado del Perú

Juan C. Quispe¹; Michael Huaman²; José Pauyac³

^{1,2,3} Universidad Tecnológica del Perú, Perú

C21675@utp.edu.pe, u19209764@utp.edu.pe, u19212892@utp.edu.pe

Resumen— El presente trabajo evalúa el desempeño del modelo SARIMA en el pronóstico de la demanda eléctrica de corto plazo (diaria) del sistema eléctrico peruano, resaltando su capacidad para capturar patrones estacionales y variaciones intradiarias inherentes al comportamiento de la carga. Mediante la incorporación de componentes autorregresivos, de diferenciación y estacionales, el modelo reproduce de manera adecuada las fluctuaciones diarias, generando estimaciones consistentes y coherentes con la dinámica histórica de la serie. Asimismo, los resultados evidencian la robustez, interpretabilidad y eficiencia computacional del enfoque propuesto, lo que lo convierte en una alternativa competitiva frente a métodos más complejos. De esa manera, el modelo SARIMA se posiciona como una herramienta competitiva para los procesos de planificación operativa y toma de decisiones en el corto plazo dentro de los sistemas eléctricos de potencia.

Palabras clave— corto plazo, demanda, pronóstico, SARIMA.

I. INTRODUCCIÓN

El pronóstico de la demanda de energía eléctrica es un área crítica y en continuo desarrollo dentro de los sistemas eléctricos de potencia, puesto que permite una planificación más eficiente de la generación, transmisión y distribución de la energía, además, reduce los costos operativos y contribuye a la estabilidad del sistema. En la literatura científica se muestra una evolución de diferentes métodos como: estadísticos, basados en aprendizaje automático e inteligencia artificial, así como modelos híbridos que combinan diferentes técnicas.

En referencia al pronóstico, los modelos estadísticos clásicos como ARIMA, SARIMA y modelos de regresión se emplearon ampliamente debido a su simplicidad y capacidad de modelar tendencias y estacionalidades en series temporales de consumo. Estudios recientes han evaluado la robustez de ARIMA frente a ruido y perturbaciones aleatorias en los datos de carga, evidenciando que la fase de preprocesamiento es clave para su desempeño y que su capacidad de ajuste puede ser limitada en entornos con alta variabilidad no lineal [1], [2].

Con el avance de las tecnologías de medición y almacenamiento de datos, la investigación ha considerado enfoques sobre técnicas de aprendizaje automático y deep learning. Las redes neuronales artificiales (ANN) han sido ampliamente aplicadas para capturar relaciones no lineales complejas entre variables históricas de carga, condiciones climáticas, calendáricas, socioeconómicas, entre otros factores;

mostrando una mejor precisión que los métodos clásicos [3]. Dentro de los enfoques de inteligencia artificial, modelos como LSTM (Long Short-Term Memory) y RNN han demostrado su habilidad para aprender patrones secuenciales relevantes en series temporales de demanda, reduciendo los errores de predicción en comparación con métodos lineales tradicionales [4], [5]. La literatura también señala que modelos híbridos que integran componentes estadísticos con redes neuronales o combinan múltiples métodos de machine learning suelen ofrecer mejoras adicionales en precisión y estabilidad [6], [7]. Por ejemplo, la combinación de SARIMA con redes neuronales de retropropagación o con redes profundas como CNN-LSTM ha permitido capturar patrones tanto lineales como no lineales más complejos, proporcionando pronósticos más consistentes especialmente en escenarios con alta volatilidad de la demanda [8]. Además, en trabajos comparativos se observa que métodos como Support Vector Machines (SVM), gradient boosting (XGBoost, LightGBM), ensemble learning y modelos basados en similitud de patrones constituyen alternativas importantes al enfoque ANN/LSTM, particularmente cuando se requiere robustez frente a ruido o gran heterogeneidad de datos [9]. Sin embargo, se considera que para la ejecución de estos métodos requiere contar con alta capacidad computacional y amplia data histórica.

Por otro lado, gran parte de los estudios según el horizonte de predicción: corto plazo (horas a días), mediano plazo (semanas a meses) y largo plazo (años). Se ha observado que los avances en deep learning y modelos híbridos han mejorado sustancialmente el desempeño en predicciones de corto y mediano plazo, mientras que en largo plazo aún se mantienen relevantes tanto los modelos estadísticos como otros enfoques de machine learning con variables exógenas (climáticas como temperatura y humedad, calendáricas y económicas). Sin embargo, a pesar de los avances significativos, las técnicas de aprendizaje automático y deep learning aplicadas al pronóstico de demanda eléctrica aún presentan limitaciones relevantes ampliamente discutidas en la literatura. Una de las principales es la alta dependencia de grandes volúmenes de datos históricos de buena calidad, lo que dificulta su aplicación en sistemas con información incompleta, ruidosa o de corta duración, situación común en países en desarrollo o en nuevas áreas de demanda [10], [11]. Asimismo, los modelos profundos como LSTM y CNN-LSTM presentan baja interpretabilidad, lo que limita su

aceptación por operadores y reguladores del sistema eléctrico que requieren explicaciones claras para la toma de decisiones técnicas y económicas [12], [13]. Otra limitación importante es su alto costo computacional y complejidad en el ajuste de hiperparámetros, lo que incrementa los tiempos de entrenamiento y el riesgo de sobreajuste si no se aplican técnicas adecuadas de validación [14], [15]. Además, diversos estudios señalan que el desempeño de estos modelos es altamente dependiente de las condiciones del contexto, por lo que arquitecturas entrenadas en un sistema eléctrico específico no necesariamente generalizan bien a otros sistemas con características climáticas, socioeconómicas o regulatorias distintas [16]–[18].

En Latinoamérica, el pronóstico de demanda eléctrica ha evolucionado desde el uso predominante de modelos estadísticos clásicos como ARIMA y SARIMA valorados por su simplicidad y capacidad para modelar tendencias y estacionalidades hacia la adopción de técnicas de machine learning y deep learning, motivada por el aumento de la variabilidad de la demanda y la influencia de factores climáticos y socioeconómicos. Estudios aplicados en países como Brasil, Colombia y Chile muestran que modelos como redes neuronales, LSTM y enfoques híbridos SARIMA–ML ofrecen mejoras significativas en precisión al capturar relaciones no lineales y dependencias temporales complejas; no obstante, también ha evidenciado desafíos asociados al alto costo computacional, complejidad en el ajuste de hiperparámetros y riesgo de sobreajuste [7], [19]

En el contexto actual, aún es necesaria mayor investigación aplicada a redes eléctricas específicas como la peruana o Sistema Eléctrico Interconectado Nacional (SEIN), donde los patrones de consumo de alta demanda de usuarios libres, creciente integración de fuentes de energías renovables, uso de sistemas ligeros, comportamiento de la demanda representan retos particulares que no siempre son directamente abordados por modelos generalizados de pronóstico. En ese sentido el presente trabajo se enfoca en la evaluación del método SARIMA con el fin de evidenciar si este modelo aún es más conveniente para la situación actual del sistema eléctrico peruano.

II. METODOLOGÍA

A. Modelos SARIMA

Partiendo del modelo ARIMA combina tres procesos estadísticos: AR (AutoRegresivo), utiliza valores pasados de la serie para predecir valores futuros. I (Integrado) el cual aplica diferenciación para volver estacionaria la serie (eliminar tendencias) y MA (Media Móvil) donde utiliza errores pasados (residuos) para mejorar la predicción. En ese sentido el modelo general se expresa como ARIMA (p, d, q).

Los modelos SARIMA (Seasonal AutoRegresive Integrated Moving Average) constituyen una extensión de los modelos ARIMA tradicionales, incorporando explícitamente la componente estacional de las series temporales, característica fundamental en la demanda de energía eléctrica debido a

patrones diarios, semanales y anuales. Un modelo SARIMA se expresa como SARIMA (p, d, q) (P, D, Q), donde (p, d, q) representan los órdenes autorregresivos, de diferenciación y de media móvil no estacionales, mientras que (P, D, Q) describen los componentes estacionales con periodicidad s .

- P : orden autorregresivo estacional
- D : grado de diferenciación estacional
- Q : orden de media móvil estacional
- m : periodicidad de la estacionalidad

El modelo completo se representa como:

$$\text{SARIMA}(p, d, q)(P, D, Q)M \quad (1)$$

Esto permite capturar tanto la dinámica no estacional como la estacional de la serie. Además, la serie debe volverse estacionaria tras aplicar las diferenciaciones necesarias, los residuos del modelo deben comportarse como ruido blanco (sin autocorrelación) y requiere suficiente data histórica para identificar patrones.

En referencia al análisis se parte de la exploración de la serie (tendencias, estacionalidad, ruido), luego la diferenciación para lograr estacionariedad, seguido de la identificación de parámetros mediante gráficos ACF y PACF, luego la estimación del modelo, la validación mediante análisis de residuos y finalmente el pronóstico como se muestra en la figura 1.

B. Características de la demanda del sistema eléctrico peruano.




Fig. 1 Flujo del proceso del método SARIMA

La demanda del sistema eléctrico peruano o SEIN se caracteriza por un crecimiento históricamente asociado al desempeño de la actividad económica similar a los países cercanos a la región; en el caso peruano con una alta influencia

de los sectores minero, industrial y comercial, que concentran una proporción significativa del consumo total. Además, la demanda máxima coincidente ha oscilado cerca de los 7 700–8 000 MW, alcanzando valores como 7 995 MW en enero de 2026 y alrededor de 7 900 MW en diciembre de 2025, registrados en horas punta alrededor de las 19:00–20:00 h [20]. La demanda presenta una clara estacionalidad diaria, con máximos por la tarde-noche y mínimos en la madrugada y presenta una marcada variación diaria y semanal, así como diferencias entre días laborables y fines de semana. A nivel estacional, la demanda muestra variaciones moderadas a lo largo del año, influenciadas por condiciones climáticas, ciclos productivos y patrones de consumo urbano, siendo Lima la región como mayor demanda vegetativa y en el área sur por presentar cargas mineras.

La demanda eléctrica del Perú presenta tendencia, estacionalidad y variaciones aleatorias marcadas a lo largo del día, con un patrón recurrente. Referente al comportamiento diario típico (curva de carga, ver figura 2) existen ciertos patrones más comunes del día:

1) *Mínima demanda*: Entre 00:00 y 09:00, donde predominan consumos esenciales industriales y cargas de base, se caracteriza por tener bajo consumo.

2) *Media demanda*: Meseta diurna: Entre 10:00 y 17:00 consumo relativamente estable, asociado a las actividades productivas, comerciales y servicios; también denominada demanda media.

3) *Máxima demanda*: Entre 18:00 y 23:00, en muchos casos identificado como el periodo de mayor carga del sistema; sin embargo, no implica que siempre represente el pico de demanda, en muchos casos la máxima demanda se presenta en la meseta diurna como se muestra en la figura 2.

Referente a la influencia de factores externos o evento no recurrentes que afectan el comportamiento normal (feriados, eventos sociales, etc.). Se ha identificado que estas características son relevantes que deben modelarse como un caso particular en los pronósticos diarios.




Fig. 2 Perfil de demanda diaria (cada 30 minutos) de todo del SEIN correspondiente a un día aleatorio (15.12.25). Fuente COES [20]

El SEIN presenta un comportamiento eléctrico que varía según el día de la semana, producto de hábitos comerciales y

sociales. La evidencia estadística señala diferencias por día, requiriendo modelos específicos para cada uno. Tendencias semanales típicas de lunes a viernes se presenta mayor carga promedio diaria; además, presenta curvas con picos matinales y nocturnos bien definidos y se caracteriza por la influencia de la actividad industrial y comercial.

Referente a los sábados presenta una reducción moderada de la carga por lo que implica el aplanamiento de la curva durante el día. Finalmente, los domingos y feriados son los días con menor demanda del sistema cuya curva con menor meseta diurna y picos menos pronunciados; además, predomina el consumo residencial y cargas esenciales. En la figura 3 se puede observar el comportamiento de una semana.




Fig. 3 Perfil de demanda semanal de todo del SEIN correspondiente a una semana aleatoria (15.12.25 – 21.12.25). Fuente COES [20]

C. Modelo propuesto.

En referencia a la adquisición y estructuración de datos de entrada, se considera una variable independiente conformada por una serie histórica de demanda del SEIN (en MW). Específicamente, se empleó un registro de 60 días correspondientes a enero y febrero de 2025. Tras el proceso de evaluación de estrés computacional, se aplicó un downsampling fijando la frecuencia en 24 puntos por día. Esto establece un tamaño de muestra exacto de $N = 1440$ observaciones, un volumen estadísticamente significativo e idóneo para garantizar la convergencia paramétrica de la matriz sin comprometer la estabilidad computacional.

En referencia a la adquisición y estructuración de datos de entrada, se considera una serie histórica de demanda del SEIN (en MW) con frecuencia diaria de 48 puntos por día. Para la estructuración se consolidan los datos mediante un vector cronológico continuo; además, se verifican con datos faltantes y atípicos, luego se convierte a formato “time series, además, se indexa por fecha. Cabe destacar que toda la implementación metodológica de este trabajo se desarrolló utilizando el lenguaje de programación Python. Para el preprocesamiento, limpieza e indexación temporal de los datos se empleó la librería Pandas. Asimismo, las iteraciones de estimación estadística, la validación de los modelos y la generación visual de las funciones ACF/PACF y de los residuos (mostradas en las

figuras posteriores) se ejecutaron mediante la librería Statsmodels, asegurando así el rigor analítico y la reproducibilidad técnica del proceso. El diagrama de la figura 4 representa una estructura básica típica de un flujograma de procesos.

El componente AR capta cómo la demanda actual depende de días recientes. La diferenciación elimina tendencias y estabiliza la serie. El componente MA capta shocks o variaciones aleatorias recientes. Los componentes estacionales capturan el patrón repetitivo diario y semanal del SEIN (lunes–domingo). Referente al proceso se analiza gráficas ACF y PACF para seleccionar p , q , P , Q . Aplicar pruebas de estacionariedad (ADF o KPSS). Probar combinaciones iniciales basadas en:

$(p, q) \rightarrow$ forma local de la curva de demanda

$(P, Q) \rightarrow$ patrón semanal detectado en ACF

Entrenamiento del modelo, ajustar el modelo SARIMA a la serie histórica. Estimar parámetros mediante máxima verosimilitud y finalmente evaluar ajuste.




Fig. 4 Flujo de proceso para la evaluación del método SARIMA en el pronóstico de la demanda de corto plazo del SEIN

En referencia a la validación y prueba, el test de Ljung-Box $Q > 90$ en modelos de series temporales, el estadístico Q mide si los residuos (el error que queda tras el modelo) son ruido blanco (aleatorios) o si todavía contienen información. Al buscar una confianza del 91% al 99%, se está asegurando que el modelo ha extraído prácticamente toda la estructura de los datos del SEIN. Si el valor de p asociado a Q es bajo, el modelo falla porque no está "entendiendo" algo de la serie de 48 puntos. Con respecto a la estabilidad de la Matriz (> 2 semanas), este es un parámetro de "estrés computacional". Al trabajar con SARIMA, la matriz de coeficientes crece exponencialmente con la frecuencia de los datos. Si al intentar procesar mucha información puede la matriz no converger o los errores se disparan llegando a una inestabilidad numérica. En ese sentido, la decisión de Downsampling implica que la metodología se vuelve adaptativa, si no se cumple la estabilidad, el flujo retrocede automáticamente para reducir la granularidad (de 48 a 24 o 12 puntos, por ejemplo).

III. RESULTADOS

La evaluación del análisis consideró un registro de 60 días de data histórica de enero y febrero del 2025 con el objetivo de predecir la demanda de 01 de marzo del 2025. Luego de la evaluación del modelo se identificó un proceso ajuste en el Downsampling pasando de 48 puntos por día a 24 puntos, este permitió una mejor performance de los resultados. Además, se evidenció los bajos recursos que requiere este método para la ejecución del pronóstico de demanda.

En la Figura 5 evidencia que la serie original no es estacionaria, lo cual se manifiesta en la ACF con autocorrelaciones significativas que se mantienen a lo largo de numerosos rezagos y presentan un patrón oscilatorio persistente. Este comportamiento indica una fuerte dependencia temporal y la posible presencia de tendencia o componentes cíclicas. En ese sentido, la PACF de la serie original no muestra un corte claro en pocos rezagos, lo que descarta una estructura autorregresiva simple y refuerza la necesidad de aplicar una transformación previa antes de cualquier proceso de modelación. Tras aplicar una diferenciación de primer orden (D1), se observa un cambio sustancial en el comportamiento de la serie.




Fig. 5. Características del perfil del ACF y PACF

La ACF de la serie diferenciada presenta un decaimiento rápido de las autocorrelaciones, con la mayoría de los coeficientes dentro de los límites de confianza, mientras que la PACF muestra un pico dominante en el primer rezago. Estos resultados confirman que la diferenciación logra estabilizar la serie, haciéndola aproximadamente estacionaria y adecuada para la modelación mediante un enfoque de tipo SARIMA con parámetros de bajo orden.

La figura 6 muestra las gráficas de los residuos estandarizados donde evidencia que estos se distribuyen alrededor de cero sin una tendencia clara en el tiempo, lo que sugiere que el modelo captura adecuadamente la dinámica sistemática de la serie. Sin embargo, se observan algunos valores atípicos de magnitud elevada, indicativos de choques puntuales no explicados completamente por el modelo.




Fig. 6. Graficas de residuos estandarizados

El histograma, junto con la densidad estimada, presenta una forma aproximadamente simétrica y centrada en cero, cercana a una distribución normal estándar, aunque con colas ligeramente más pesadas que la normal teórica.

Por otro lado, el gráfico Q-Q evidencia que la mayor parte de los cuantiles empíricos se alinean razonablemente con la recta teórica, confirmando una normalidad aceptable de los residuos, con desviaciones principalmente en los extremos. Finalmente, el correlograma de los residuos muestra que las autocorrelaciones se mantienen dentro de los límites de confianza, lo que indica ausencia de dependencia temporal significativa. En conjunto, estos resultados sugieren que los residuos se comportan de manera cercana a ruido blanco, validando de forma general la idoneidad del modelo ajustado.

La gráfica de la figura 7 muestra el pronóstico generado mediante el modelo SARIMA con estacionalidad diaria ($m = 24$), donde la serie histórica evidencia un patrón cíclico bien definido y recurrente, con oscilaciones regulares propias de un comportamiento estacional horario. El modelo logra capturar adecuadamente esta dinámica, proyectando para el 1 de marzo de 2025 una trayectoria coherente con los niveles y la forma de la serie observada, sin cambios bruscos ni rupturas estructurales respecto al comportamiento previo.




Fig. 7. Comportamiento del pronóstico y su tendencia el perfil de demanda para una semana.

Asimismo, el intervalo de confianza asociado al pronóstico se amplía conforme avanza el horizonte de predicción, reflejando el incremento natural de la incertidumbre a futuro. La trayectoria central del pronóstico se mantiene dentro de rangos consistentes con los valores históricos, mientras que la amplitud del intervalo indica una variabilidad moderada, compatible con la dispersión observada en la serie. En conjunto, la gráfica sugiere que el modelo SARIMA proporciona un pronóstico razonable y estable en el corto plazo, siendo adecuado para análisis operativos que requieran anticipar el comportamiento esperado de la variable bajo condiciones similares a las históricas. Además, en la Tabla 1 se muestra los valores obtenidos.

Para cuantificar la eficacia y calidad del modelo propuesto, se calcularon las métricas de error estándar empleadas en pronósticos de series temporales. Al comparar los valores reales del 1 de marzo de 2025 con los pronosticados, el modelo obtuvo un Error Cuadrático Medio (RMSE) de 74.79 MW, un Error Absoluto Medio (MAE) de 56.90MW y un Error Porcentual Absoluto Medio (MAPE) de 0.81 %. Estos indicadores (KPIs)

confirman estadísticamente la alta precisión del pronóstico, evidenciando una desviación mínima respecto a la variabilidad real de la curva de carga del sistema

TABLA I
PRONOSTICO GENERADO PARA EL 01.03.2025

Horario	Predicción MW	Límite inferior	Límite superior
01/03/2025 00:00	7117.07	6847.46	7386.68
01/03/2025 01:00	6911.42	6471.63	7351.21
01/03/2025 02:00	6868.14	6272.64	7463.64
01/03/2025 03:00	6821.02	6088.71	7553.34
01/03/2025 04:00	6749.68	5895.51	7603.86
01/03/2025 05:00	6816.27	5852.44	7780.10
01/03/2025 06:00	6824.06	5760.35	7887.76
01/03/2025 07:00	6952.50	5796.81	8108.20
01/03/2025 08:00	7245.67	6004.45	8486.89
01/03/2025 09:00	7467.88	6146.49	8789.26
01/03/2025 10:00	7574.42	6177.38	8971.46
01/03/2025 11:00	7653.55	6184.71	9122.40
01/03/2025 12:00	7632.53	6095.21	9169.85
01/03/2025 13:00	7586.65	5983.77	9189.53
01/03/2025 14:00	7646.57	5980.71	9312.44
01/03/2025 15:00	7685.41	5958.85	9411.97
01/03/2025 16:00	7678.49	5893.30	9463.68
01/03/2025 17:00	7474.23	5632.27	9316.19
01/03/2025 18:00	7421.64	5524.61	9318.67
01/03/2025 19:00	7533.22	5582.68	9483.76
01/03/2025 20:00	7536.84	5534.21	9539.47
01/03/2025 21:00	7469.88	5416.49	9523.27
01/03/2025 22:00	7406.69	5303.76	9509.63
01/03/2025 23:00	7255.26	5103.92	9406.59

La gráfica de la figura 8 presenta la comparación entre los valores reales y el pronóstico para el 1 de marzo de 2025, donde se observa que el modelo reproduce de manera adecuada la forma general del perfil horario. Tanto la serie real como la pronosticada muestran un incremento progresivo durante las primeras horas del día, alcanzando valores máximos en el periodo central, seguido de una disminución hacia las horas de la madrugada. Esta coincidencia en la tendencia y en los puntos de inflexión evidencia que el modelo captura correctamente la dinámica intradiaria de la variable analizada.

Los valores reales se mantienen en todo momento dentro del intervalo de confianza del pronóstico, lo que indica un buen desempeño predictivo y una adecuada cuantificación de la incertidumbre. Si bien se observan pequeñas diferencias puntuales entre la serie real y la estimada, estas no son sistemáticas ni de gran magnitud. En conjunto, los resultados

sugieren que el modelo presenta una precisión satisfactoria en el corto plazo, siendo confiable para análisis operativos y toma de decisiones basada en el comportamiento esperado de la serie.




Fig. 8. Comparación de la data real y el valor pronosticado.

Adicionalmente, los pronósticos generados presentan coherencia con los valores históricos y mantienen una evolución estable en el corto plazo, mientras que los intervalos de confianza reflejan de forma realista la incertidumbre asociada al horizonte de predicción. La comparación entre valores reales y pronosticados para el 1 de marzo de 2025 evidenció que las observaciones reales se encuentran dentro de los rangos estimados, confirmando un desempeño predictivo satisfactorio y la utilidad del modelo para aplicaciones operativas y de apoyo a la toma de decisiones

Al contrastar la eficacia de este trabajo con estudios recientes, se observa que los enfoques basados en redes neuronales (ANN) o modelos profundos como LSTM suelen reportar márgenes de error (MAPE) entre el 1.5% y el 3.0% en sistemas interconectados de similar complejidad [2], [3]. Por otro lado, el modelo propuesto SARIMA, ha logrado un MAPE competitivo del 81 %, demuestra ser una investigación trascendente para la operación de la red. A diferencia de las metodologías de caja negra, el enfoque propuesto logra un nivel de impacto predictivo equivalente, ofreciendo beneficios superiores en cuanto a interpretabilidad regulatoria, menor demanda de capacidad de procesamiento y alta robustez paramétrica.

IV. CONCLUSIONES

El análisis de la evaluación del método SARIMA permitió capturar de manera efectiva los patrones estacionales y la dinámica temporal de la demanda diaria del sistema eléctrico de esa manera presentó un adecuado comportamiento en referencia a las características de la demanda del SEIN. La evaluación de las funciones ACF y PACF confirmó la necesidad de aplicar una diferenciación de primer orden, tras la cual la serie mostró propiedades cercanas a la estacionariedad, condición fundamental para una modelación adecuada. En este contexto, el modelo SARIMA seleccionado logró capturar de forma consistente tanto la estructura temporal como la estacionalidad horaria de la serie, reproduciendo correctamente sus principales patrones cíclicos.

En conjunto, los resultados demuestran que el método SARIMA constituye aún una herramienta sólida y eficiente para el apoyo en la planificación operativa y la programación de la operación en sistemas eléctricos con patrones de carga claramente estacionales. Adicionalmente, es preciso resaltar que este modelo demostrado su adecuado comportamiento en el pronóstico de corto plazo de demanda eléctrica por su sólido fundamento estadístico, interpretabilidad y eficiencia computacional, mostrando buen desempeño cuando la serie presenta comportamiento lineal y estacional bien definido siendo competitivo frente a métodos más complejos, especialmente cuando requieren más información histórica, o equipos con alta capacidad de procesamiento, he incluso interpretación compleja.

Por otro lado, en los últimos años, se ha evidenciado una mayor sensibilidad a la generación renovable variable, a la electrificación de procesos productivos y a cambios en el consumo residencial. Estas características hacen necesario el continuo análisis de los modelos de pronóstico horario a corto plazo, que permitan anticipar la demanda con precisión.

REFERENCIAS

- [1] E. Chodakowska, J. Nazarko, and Ł. Nazarko, "ARIMA Models in Electrical Load Forecasting and Their Robustness to Noise," *Energies* 2021, Vol. 14, Page 7952, vol. 14, no. 23, p. 7952, Nov. 2021, doi: 10.3390/EN14237952.
- [2] N. T. N. Anh, N. N. Anh, T. N. Thang, V. K. Solanki, R. G. Crespo, and N. Q. Dat, "Online SARIMA applied for short-term electricity load forecasting," *Appl. Intell.*, vol. 54, no. 1, pp. 1003–1019, Jan. 2024, doi: 10.1007/S10489-023-05230-Y.
- [3] A. Román-Portabales, M. López-Nores, and J. J. Pazos-Arias, "Systematic Review of Electricity Demand Forecast Using ANN-Based Machine Learning Algorithms," *Sensors* 2021, Vol. 21, Page 4544, vol. 21, no. 13, p. 4544, Jul. 2021, doi: 10.3390/S21134544.
- [4] N. B. Vanting, Z. Ma, and B. N. Jørgensen, "A scoping review of deep neural networks for electric load forecasting," *Energy Informatics* 2021 42, vol. 4, no. 2, pp. 49–, Sep. 2021, doi: 10.1186/S42162-021-00148-6.
- [5] Y. Zhou, Z. Su, K. Gao, Z. Wang, W. Ye, and J. Zeng, "A short-term electricity load forecasting method integrating empirical modal decomposition with SAM-LSTM," *Front. Energy Res.*, vol. 12, p. 1423692, Jun. 2024, doi: 10.3389/FENRG.2024.1423692/TEXT.
- [6] N. Pooniwalla and R. Sutar, "Forecasting Short-Term Electric Load with a Hybrid of ARIMA Model and LSTM Network," *2021 Int. Conf. Comput. Commun. Informatics, ICCCI 2021*, Jan. 2021, doi: 10.1109/ICCCI50826.2021.9402461.
- [7] J. D. V. Henao, V. M. R. Mejía, and C. J. F. Cardona, "Electricity demand forecasting using a sarima-multiplicative single neuron hybrid model," *DYNA Rev. la Fac. Minas. Univ. Nac. Colomb. Sede Medellín, ISSN 0012-7353, Vol. 80, Nº. 180, 2013, págs. 4-8*, vol. 80, no. 180, pp. 4–8, 2013.
- [8] Y. Chen, C. Liu, J. Ge, J. Wu, X. Zhao, and Z. Gao, "Deep learning models for forecasting electricity demand in green low-carbon supply chains," *Int. J. Low-Carbon Technol.*, vol. 19, pp. 2375–2382, Jan. 2024, doi: 10.1093/IJLCT/CTAE186.
- [9] A. Maneshni, Y. Weng, A. Ewaisha, and D. Delp, "Load Forecasting in the Era of Smart Grids: Opportunities and Advanced Machine Learning Models," May 2025, Accessed: Jan. 26, 2026. [Online]. Available: <https://arxiv.org/pdf/2505.18170>.
- [10] T. Hong and S. Fan, "Probabilistic electric load forecasting: A tutorial review," *Int. J. Forecast.*, vol. 32, no. 3, pp. 914–938, Jul. 2016, doi: 10.1016/J.IJFORECAST.2015.11.011.
- [11] I. K. Nti, A. F. Adekoya, and B. A. Weyori, "Efficient Stock-Market Prediction Using Ensemble Support Vector Machine," *Open Comput. Sci.*, vol. 10, no. 1, pp. 153–163, Jan. 2020, doi: 10.1515/COMP-2020-0199/XML.
- [12] A. Mosavi, P. Ozturk, and K. W. Chau, "Flood Prediction Using Machine Learning Models: Literature Review," *Water* 2018, Vol. 10, Page 1536, vol. 10, no. 11, p. 1536, Oct. 2018, doi: 10.3390/W10111536.
- [13] N. Zhang, S. L. Shen, A. Zhou, and Y. F. Jin, "Application of LSTM approach for modelling stress-strain behaviour of soil," *Appl. Soft Comput.*, vol. 100, p. 106959, Mar. 2021, doi: 10.1016/J.ASOC.2020.106959.
- [14] C. Voyant *et al.*, "Machine learning methods for solar radiation forecasting: A review," *Renew. Energy*, vol. 105, pp. 569–582, May 2017, doi: 10.1016/J.RENENE.2016.12.095.
- [15] K. Amarasinghe, D. L. Marino, and M. Manic, "Deep neural networks for energy load forecasting," *IEEE Int. Symp. Ind. Electron.*, pp. 1483–1488, Aug. 2017, doi: 10.1109/ISIE.2017.8001465.
- [16] R. Weron, "Electricity price forecasting: A review of the state-of-the-art with a look into the future," *Int. J. Forecast.*, vol. 30, no. 4, pp. 1030–1081, Oct. 2014, doi: 10.1016/J.IJFORECAST.2014.08.008.
- [17] U. Mumtahina, S. Alahakoon, and P. Wolfs, "Hyperparameter Tuning of Load-Forecasting Models Using Metaheuristic Optimization Algorithms—A Systematic Review," *Math.* 2024, Vol. 12, Page 3353, vol. 12, no. 21, p. 3353, Oct. 2024, doi: 10.3390/MATH12213353.
- [18] R. Chandrasekaran and S. K. Paramasivan, "Advances in Deep Learning Techniques for Short-term Energy Load Forecasting Applications: A Review," *Arch. Comput. Methods Eng.* 2024 322, vol. 32, no. 2, pp. 663–692, Jun. 2024, doi: 10.1007/S11831-024-10155-X.
- [19] H. S. Hippert, C. E. Pedreira, and R. C. Souza, "Neural networks for short-term load forecasting: A review and evaluation," *IEEE Trans. Power Syst.*, vol. 16, no. 1, pp. 44–55, Feb. 2001, doi: 10.1109/59.910780.
- [20] "Portal Web del COES:," <https://www.coes.org.pe/portal/> (accessed Feb. 16, 2026).