

Modelo de Demanda Eléctrica Mediante Ciencia de Datos y Machine Learning: Caso Sistema Eléctrico del Ecuador

Electricity Demand Model Using Data Science and Machine Learning: Case Study of the Ecuadorian Electricity System

Jesús A. Pérez Rodríguez^{1*}, Leonardo Chancay García¹, Mariuxi Guillen Intriago^{II}

^I Universidad Técnica de Manabí. Portoviejo, Ecuador

^{II} Escuela Superior Politécnica Agropecuaria de Manabí “Manuel Félix López”. Calceta, Ecuador

*Autor de correspondencia: jesus.perez@utm.edu.ec

Recibido: 16 de enero de 2026

Aprobado: 30 de abril de 2026

Este documento posee una [licencia Creative Commons Reconocimiento-NoComercial 4.0 internacional](https://creativecommons.org/licenses/by-nc/4.0/)



RESUMEN/ABSTRACT

En el presente trabajo se compararon modelo de aprendizaje automático y modelos estadísticos con el fin de revisar su comportamiento frente a datos multifuentes correspondientes al intervalo desde 2001 al 2025, dichos datos corresponde a valores climáticos, socioeconómicos y de energía disponible del Ecuador, esta última fue tomada como variable objetivo, fueron evaluados los modelos SARIMAX, XGBoost y LightGBM, en una comparación de validación temporal, los resultados encontrados presentan a SARIMAX con un desempeño superior a los otros ($R^2=0.987$; $MAPE<1\%$), evidenciado la autocorrelación, estacionalidad y las tendencias, de esta manera se muestra que los modelos de aprendizaje automático, excluyendo los modelos híbridos, no siguen cambios drásticos, obteniéndose bajos niveles de precisión en los resultados, también se evidencia la colinealidad de la energía facturada con la disponible, siendo coherente con las restricciones estructurales del sistema, siendo la dinámica del tiempo preponderante de las complejidades del modelo.

Palabras clave: demanda eléctrica, SARIMAX, Machine learning, energía disponible.

In this study, machine learning and statistical models were compared to examine their performance on multi-source data from 2001 to 2025. This data includes climatic, socioeconomic, and available energy values for Ecuador, with the latter being the target variable. The SARIMAX, XGBoost, and LightGBM models were evaluated in a temporal validation comparison. The results show SARIMAX outperforming the others ($R^2=0.987$; $MAPE<1\%$), demonstrating autocorrelation, seasonality, and trends. This shows that machine learning models, excluding hybrid models, do not follow drastic changes, resulting in low levels of accuracy. The collinearity between billed and available energy is also evident, consistent with the system's structural constraints, with time dynamics being the predominant factor in the model's complexities.

Key words: electricity demand forecasting, SARIMAX, Machine learning, energy availability.

INTRODUCCIÓN

Debido al desarrollo tecnológico, la urbanización y la electrificación de distintos sectores, el pronóstico de la demanda eléctrica se ha convertido en una parte significativa para la planificación y el funcionamiento eficaz de los sistemas energéticos contemporáneos, debido al aumento continuo de la demanda de energía. La electricidad es un pilar clave para el desarrollo económico y social, ya que es esencial para la operación de infraestructuras, la industria o los servicios digitales.

Pero la demanda creciente junto con el cambio de combustibles fósiles a renovables intermitentes ha hecho que el trabajo de mantener el equilibrio entre generación y consumo sea mucho más complicado. Cómo citar este artículo:

Jesús A. Pérez Rodríguez y otros. Modelo de Demanda Eléctrica Mediante Ciencia de Datos y Machine Learning: Caso Sistema Eléctrico del Ecuador. Ingeniería Energética. Vol. 47(2026): publicación continua. ISSN 1815-5901.

Sitio de la revista: <https://rie.cujae.edu.cu/index.php/RIE/index>

[1]. Se necesitan estudios precisos de la demanda futura de electricidad para operar el sistema de la manera más óptima posible, lo que reduce los costos y garantiza la estabilidad de la red. En proyectos de generación pequeños errores en la estimación de la demanda puede ocasionar pérdidas económicas importantes, lo que incide en la necesidad de contar con procedimientos que sean precisos y consistentes con valores de desempeño registrados por la literatura científica [1]. En el pasado los modelos más utilizados para abordar series de tiempo son los estadísticos tales como ARIMA y sus extensiones, que han demostrado tener un alto desempeño en aplicaciones donde se requiera modelar patrones temporales y estacionales a partir de un conjunto de datos.

En muchos casos se han aplicado los modelos SARIMA y SARIMAX porque tienen en cuenta la estacionalidad y permiten variables externas como valores climáticos y socioeconómicos. Esto tendría un impacto clave en el rendimiento de la demanda de electricidad, posibilitando la interseccionalidad multidimensional entre efectos variables para ocurrir simultáneamente en sistemas altamente complejos [2]. En este sentido, SARIMAX permite representar relaciones más realistas al integrar información externa en el proceso de predicción. No obstante, estos modelos presentan limitaciones al capturar relaciones altamente no lineales, lo que ha motivado la exploración de enfoques alternativos [3].

El continuo desarrollo tecnológico como digitalización de procesos, datos abiertos e inteligencia artificial ha dado paso al uso de métodos de aprendizaje automático en la predicción de la demanda de energía. Los métodos soportados en herramientas de Machine Learning han sido utilizados por su particularidad en abordar problemas de patrones complejos y no lineales, los cuales divergen de los métodos clásicos, puestos que estas herramientas pueden ser más precisas en la predicción [4]. En concreto, existen varias aplicaciones de pronóstico de energía que emplean algunos algoritmos especiales, por ejemplo: Máquinas de Vectores de Soporte, Random Forest, Redes Neuronales, entre otros [5].

Estudios más recientes indican que las arquitecturas de aprendizaje profundo, especialmente las redes neuronales recurrentes (RNN) y las redes Long Short-TermMemory (LSTM), tienen un mejor desempeño predictivo en series temporales complejas debido a su capacidad para modelar dependencias temporales de largo alcance [6]. De manera similar, revisiones modernas indican que arquitecturas de aprendizaje profundo como CNN-LSTM, han reducido considerablemente los errores de predicción, en órdenes de magnitud inferiores al 5% de MAPE en algunos escenarios [7].

En la misma línea, trabajos de investigación recientes basados en modelos que utilizan aprendizaje profundo para la predicción sugieren que, a pesar de su alta precisión, su eficiencia está determinada principalmente por la integridad de los datos, el preprocesamiento y la selección de características [8]. Más específicamente, la introducción de variables exógenas, datos meteorológicos y características de series temporales han demostrado mejorar de manera drástica la eficiencia predictiva de los modelos [6]. Otro trabajo reciente destaca la importancia de las estrategias de preprocesamiento y de aumento de datos para mejorar la capacidad de generalización del modelo en situaciones con datos limitados o ruidosos [9].

Por lo general, la literatura de vanguardia en la actualidad apunta a modelos híbridos que combinan métodos estadísticos y aprendizaje automático [10]. Estos modelos intentan aprovechar el poder interpretativo de los métodos clásicos, como SARIMAX, junto con la flexibilidad de los modelos de aprendizaje automático para captar mejor las relaciones no lineales [2]. Revisiones recientes han descrito diversos elementos para la predicción efectiva, incluida la integración o combinación de fuentes de datos y la fusión de modelos a nivel de red eléctrica [5, 11].

Aunque ha habido muchas mejoras importantes en el campo, la predicción de la demanda de electricidad sigue enfrentando diversos desafíos. Entre ellos se incluyen la necesidad de modelos interpretables, la dependencia de grandes cantidades de datos, la variabilidad introducida por fuentes renovables y los aspectos de generalización en distintos contextos geográficos [2, 8, 9, 12]. Además, estudios recientes destacan que la calidad de los datos de entrada y el paso de preprocesamiento son cruciales para el rendimiento del modelo, incluso más que el algoritmo en sí [8].

Específicamente, estos desafíos se agravan en el contexto latinoamericano debido a la falta de datos accesibles y a la heterogeneidad de los sistemas eléctricos, lo que exige modelos adecuados para las condiciones locales [3]. Si bien los desarrollos recientes en el área han mostrado un potencial cada vez mayor para los enfoques de aprendizaje automático en la previsión de la demanda eléctrica en la región, también reflejan la necesidad de elegir métodos sólidos y conscientes del contexto que tengan en cuenta las particularidades locales [3, 13].

Para resumir, el campo de la previsión de la demanda de electricidad ha evolucionado desde modelos estadísticos tradicionales hacia enfoques basados en inteligencia artificial y modelos híbridos debido al

aumento de la complejidad en los sistemas energéticos [2, 13]. El enfoque mediante modelos de aprendizaje profundo ha demostrado ser superior para ajustar patrones complejos y no lineales de series temporales [8, 9], pero modelos como SARIMAX siguen siendo relevantes para este estudio ya que ofrecen interpretabilidad y la posibilidad de incorporar variables exógenas dentro del proceso de modelado [2]. Los métodos de combinación constituyen una elección razonable en este marco, ya que la literatura reciente mostró que pueden aumentar la precisión de las predicciones [10, 11]. Con este fin, la presente investigación propone probar diferentes modelos basados en SARIMAX, así como técnicas de ML, con el objetivo de diseñar herramientas predictivas con mayor precisión, robustez y capacidad de generalización a sistemas energéticos reales en todo el mundo.

Aunque el estudio se maneja en dirección a la demanda eléctrica, la variable objetivo asumida es la energía disponible mensual (MWh), puesto que esta variable recoge la capacidad que el sistema tiene para cubrir las necesidades energéticas del Ecuador, dicha variable incorpora los distintos tipos de generación, incluyendo las compras de energía a países vecinos como Colombia y Perú.

MATERIALES Y MÉTODOS

Desarrollado con un enfoque cuantitativo aplicado, el trabajo consiste en predecir la demanda eléctrica del sistema eléctrico del Ecuador mediante la implementación y comparación (en función de la precisión, la velocidad de desempeño y la escalabilidad) de diversos métodos de modelado. En este sentido, se consideraron tanto modelos de aprendizaje automático como modelos clásicos de series de tiempo para estudiar su desempeño en alineación con las características del sistema. La metodología CRISP-ML(Q) se utiliza como referencia para estructurar el proceso de desarrollo del modelo, desde la comprensión del problema hasta la evaluación de resultados, adoptando un enfoque organizado y reproducible [14,15], adaptando sus fases a un esquema centrado en el modelado predictivo integrado con datos de múltiples fuentes [6], tal como se muestra en la figura 1.




Fig. 1. Metodología CRISP-ML(Q) Aplicada a la Predicción de la Demanda Eléctrica en Ecuador

Una vez planteado el problema de estimación de la demanda usando como variable objetivo la disponibilidad de la energía, se procedió a realizar la integración y limpieza de datos de fuentes oficiales. Estas fueron seleccionadas con base en datos históricos sobre la disponibilidad de energía eléctrica, y variables climáticas y socioeconómicas relevantes para el objetivo del estudio. Específicamente, los datos analizados consistieron en la disponibilidad de energía eléctrica total, la generación combinada y la generación desagregada por tipo de tecnología (incluyendo variables meteorológicas como temperatura y precipitación), junto con variables temporales para capturar el comportamiento estacional del consumo de energía [16].

Para el desarrollo de este trabajo se elaboró una base de datos construida con la integración, depuración y validación, de instituciones oficiales, además se prestó especial cuidado en la consolidación de los valores de energía disponible (MWh), esto representó la valoración de posibles fuentes de generación, tecnologías y su ubicación interna o externa del país., variable que fue tomada como objetivo, la cual es muy utilizada en la planificación y operación de sistemas eléctricos de potencia, además de ser fundamental para establecer la capacidad de generación.

Por el contrario, la energía facturada (MWh) se utilizó como covariable; es una métrica imperfecta pero reconocida de la demanda real registrada por las empresas nacionales de distribución. Esta distinción permitió explorar la dinámica del suministro de energía y su relación con la demanda real en el sistema.

En el estudio se realizó con frecuencia mensual, porque permite observar patrones estacionales, además de las tendencias a mediano plazo, esto mejora en la reducción del ruido operativo del sistema a corto plazo, siendo también coherente la mensualización de los datos con los procesos de planificación energética del Ecuador, simultáneamente permite que a los estudios se integre otras variables cuya selección también corresponde a periodos mensuales tales como las variables climáticas y económicas, todo esto permite tener una cantidad de datos tal que facilita el entrenamiento y validación de modelos de predicción, manteniendo un equilibrio entre la resolución temporal y la solidez de la estadística.

Se contó con un tamaño considerable del conjunto de datos en frecuencia mensual para el periodo 2001–2025, con el fin de adquirir un comportamiento dinámico de largo plazo razonable del sistema eléctrico de Ecuador. Este proceso implicó limpieza de datos, transformación y validación temporal, seguido de la generación de variables derivadas (rezagos, promedios móviles y componentes estacionales) para representar la estructura temporal de las series; no obstante, estas transformaciones no siempre son suficientes para mejorar el desempeño predictivo en sistemas donde la dependencia temporal es la variable explicativa principal [12].

Para lograr esto, se configuró un modelo dimensional en estrella conforme a lo indicado en la figura 2. mediante el uso de tablas de dimensión y tablas de hechos que resaltan la dimensión temporal como la clave de integración común entre distintas fuentes de información, estructuradas en periodos mensuales en todos los casos. Esto permitió combinar todas las variables de energía y clima en un único conjunto de datos multivariado puntual en el tiempo, evitando inconsistencias en los datos, ya que ahora están alineados temporalmente. Así, se obtuvo la información para la base de datos analítica combinada para la representación del comportamiento ecuatoriano en términos de modelado analítico y predictivo [17].




Fig. 2. Fuentes y bases de datos que integran el dataset

Las columnas relacionadas con variables explicativas pertenecientes a diferentes dimensiones del sistema en el conjunto de datos final se muestran en la tabla 1, donde se agregan variables climáticas, socioeconómicas y energéticas. Esta integración permitió el desarrollo de una representación que captura la complejidad total de las interacciones tanto internas (generación y consumo de energía) como externas (condiciones ambientales, factores económicos) dentro del sistema eléctrico. Con el objetivo de superar los límites percibidos de la previsión unidimensional, así como de investigar su diverso impacto en la precisión de la predicción, la presencia de otras dimensiones no conduce, por sí misma, a una mejora en el poder predictivo; depende de su relación con cada variable y, especialmente, considerando la estructura temporal de las series analizadas.

Tabla 1. Descripción resumida de las variables utilizadas en el dataset

Categoría	Variables incluidas	Descripción
-----------	---------------------	-------------

Categoría	Variables incluidas	Descripción
Objetivo	energia_disponible_mwh	Energía disponible mensual del sistema eléctrico ecuatoriano, utilizada como variable objetivo del modelo predictivo.
Energéticas	energia_facturada_mwh, interconexión	Variables relacionadas con el consumo energético registrado y el intercambio de energía con sistemas externos.
Temporales	anio, mes, trend, mes_sin, mes_cos	Variables que representan la evolución temporal, tendencia y estacionalidad de la serie de tiempo.
Rezagos y variables derivadas	lag_1, lag_2, lag_3, lag_6, lag_12, lag_fact, rolling_3, rolling_6, rolling_12, diff_1, diff_12	Variables obtenidas mediante ingeniería de características para capturar autocorrelación, persistencia temporal y patrones históricos del sistema eléctrico.
Climáticas	temperatura_nacional, temperatura_costa, temperatura_sierra, temperatura_amazonia, precipitacion_nacional, precipitacion_costa, precipitacion_sierra, precipitacion_amazonia, humedad_relativa_nacional, radiacion_solar, enso_oni_anomalia	Variables meteorológicas y climáticas utilizadas para evaluar la influencia de las condiciones ambientales sobre la disponibilidad energética.
Socioeconómicas	personas_por_vivienda	Indicador demográfico asociado al comportamiento potencial de la demanda energética.
Eventos	impacto_evento, evento_*	Variables binarias que representan eventos extraordinarios, anomalías o condiciones especiales con posible impacto sobre el sistema eléctrico.

Nota: Las variables derivadas fueron generadas mediante técnicas de ingeniería de características para series temporales. Las variables climáticas incluyen indicadores de temperatura, precipitación, humedad relativa, radiación solar e índice ENSO, considerando diferentes regiones geográficas del Ecuador.

Además, la verificación de validez sobre la consistencia se realizó mediante comparaciones de agregados del conjunto de datos analítico con las cifras mensuales oficiales y las tendencias acumuladas. El conjunto de datos, expresado en megavatios-hora (MWh), se construyó a partir de datos históricos del Balance de Energía Nacional y de informes técnicos derivados de entidades nacionales como el Operador Nacional de Electricidad (CENACE), la “Agencia de Regulación y Control de Electricidad” (ARCONEL), el Ministerio de Ambiente y Energía, el Banco Central del Ecuador, el INEC, NASA POWER y otros.

La consistencia de los datos fue verificada mediante la comparación entre los datos procesados y las fuentes oficiales, tales como CENACE, ARCONEL y el Balance Energético Nacional demostrando una adecuada coherencia. Esto es necesario para validar el análisis, que determina que el modelo predictivo se elaboró utilizando datos representativos del comportamiento real del sistema eléctrico ecuatoriano, las características de los datos se muestran en la tabla 2.

Tabla 2. Características generales del conjunto de datos utilizado

Característica	Descripción
Período analizado	Enero 2001 – diciembre 2025
Frecuencia temporal	Mensual
Número de observaciones	300
Variable objetivo	Energía disponible (MWh)
Variables energéticas	Energía disponible, energía facturada e interconexión
Variables climáticas	Temperatura, precipitación, humedad relativa, radiación solar e índice ENSO
Variables socioeconómicas	Personas por vivienda
Variables de eventos	Variables binarias asociadas a eventos extraordinarios
Variables derivadas	Rezagos, promedios móviles, diferencias, tendencia y componentes estacionales
Fuentes de información	CENACE, ARCONEL, INAMHI, INEC, NOAA y Banco Mundial

Modelos Predictivos

Para la realización de este estudio se seleccionaron tres modelos representativos de enfoques ampliamente utilizados en la literatura para el análisis de los pronósticos de variables energéticas. como primer modelo se seleccionó el SARIMAX, por poseer la capacidad para ser utilizado en la modelación explícita de tendencia, la autocorrelación y la estacionalidad existente en series de tiempo, también permite introducir variables exógenas, cuya expresión se presenta en la ecuación (1). En el segundo caso fue seleccionado el XGBoost y LightGBM, en ambos casos son utilizados los algoritmos de GradientBoosting, presentando un alto desempeño en problemas de predicción energética, además de capturar relaciones no lineales complejas de variables, las expresiones que establecen sus modelos matemáticos son indicadas en las ecuaciones (2 y 3). La escogencia de estos modelos permitió comprar modelos estadísticos clásicos con técnicas de aprendizaje automático, bajo las mismas condiciones temporales, dirigido a establecer cual representa de mejor manera la dinámica del sistema eléctrico ecuatoriano[2, 6, 16].

Modelo SARIMAX

$$Y_t = c + \sum_{i=1}^p \phi_i Y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \sum_{k=1}^m \beta_k X_{k,t} + \varepsilon_t \quad (1)$$

Donde: Y_t representa la energía disponible en el instante t ; c es una constante; ϕ_i son los coeficientes autorregresivos; Y_{t-i} son los valores pasados de la serie; θ_j son los coeficientes de medias móviles; ε_{t-j} son los errores pasados; β_k son los coeficientes asociados a las variables exógenas; $X_{k,t}$ representa las variables exógenas; y ε_t es el término de error aleatorio.

Modelo XGBoost

$$Obj(\theta) = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (2)$$

Donde: $Obj\theta$ representa la función objetivo a optimizar; $l(y_i, \hat{y}_i)$ es la función de pérdida entre los valores observados y predichos; y_i corresponde al valor real observado; $\hat{y}_i$ al valor estimado por el modelo; $\Omega(f_k)$ es el término de regularización; f_k representa cada árbol de decisión; K es el número total de árboles utilizados; y n es el número total de observaciones en el modelo.

Modelo LightGBM

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i) \quad (3)$$

Donde: $\hat{y}_i$ representa el valor predicho por el modelo; x_i es el vector de variables de entrada para la observación i ; f_k corresponde al árbol de decisión k ; y K es el número total de árboles construidos por el algoritmo.

Métricas de Evaluación

Continuando con el método CRISP-ML (Q), se procedió a realizar la evaluación del desempeño de los modelos, mediante el Error Absoluto Medio (MAE), tal como se indica en la ecuación (4), la Raíz del Error Cuadrático Medio (RMSE), cuyo calculo es indicado en la ecuación (5), el coeficiente de determinación (R^2), el cual se calcula mediante la ecuación (6) y el Error Porcentual Absoluto Medio (MAPE), expresión que se indica en la ecuación (7), estas métricas permiten valorar las dimensiones del error de predicción, bajo las consideraciones de magnitud del error, sensibilidad de errores grandes, capacidad explicativa y error porcentual relativo.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (6)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (7)$$

Donde: y_i es el valor real observado; $\hat{y}_i$ es el valor predicho por el modelo; $\bar{y}_i$ es el promedio de los valores observados y n es el número total de observaciones.

Finalmente, la estrategia de validación aplicada es una división basada en el tiempo en cada conjunto de datos proporcionado, donde el 80% de las observaciones pertenece al conjunto de entrenamiento y el 20% al conjunto de prueba, manteniendo órdenes similares a los de cada serie y evitando filtrar información futura hacia el pasado. Esto permitió evaluar de manera objetiva los modelos en un escenario del mundo real y también comprobar su capacidad de generalización. El modelo SARIMAX se configuro con parámetros $order=(2,1,2)$ y $seasonal_order=(1,1,1,12)$, valorando que son datos mensuales. En el caso de los modelos XGBoost y LightGBM los hiperparametros se escogieron mediante la optimización fundamentada en RandomizedSearchCV, mediante validación cruzada temporal utilizando TimeSeriesSplit con cinco particiones. En el caso de XGBoost, obtuvo 500 árboles, profundidad máxima de 5 y tasa de aprendizaje de 0.03 y para el LightGBM se obtuvo 800 árboles, 15 hojas por árbol y tasa de aprendizaje de 0.03 [3].

Dentro de las fases de implementación y monitoreo propuestas por CRISP-ML (Q), para la toma de decisiones en planificación energética, entre otras posibles áreas de aplicación, los resultados del modelo se perciben como una entrada analítica que habilita la preparación de informes técnicos. De este modo, el enfoque no se implementa para producir una aplicación de software, sino para estimar, generar tablas comparativas y gráficos de desempeño que permitan posibles análisis del comportamiento de la disponibilidad energética. Luego, se llevaron a cabo escenarios a largo plazo del comportamiento del modelo utilizando el modelo con mejor desempeño, el cual reveló una mayor capacidad para reproducir los aspectos dinámicos del sistema.

Se propone implementar el monitoreo del modelo, verificando periódicamente las métricas de error en los nuevos registros mensuales agregados y actualizando el conjunto de datos para comprobar si se cuenta con estabilidad del desempeño predictivo y, al mismo tiempo, asegurar que las estimaciones estén alineadas con la realidad a lo largo del tiempo. Estos procedimientos permitieron dar consistencia del conjunto de datos y su idoneidad para desarrollar modelos predictivos robustos, estos modelos fueron desarrollados en entornos computacionales reproducibles, empleando el lenguaje de programación Python y plataformas de ejecución en la nube como Google Colab, lo que facilitó la replicabilidad de los experimentos, la escalabilidad del análisis y la transparencia en los resultados obtenidos.

RESULTADOS

Desempeño de los modelos

Para evaluar el rendimiento predictivo de los modelos propuestos, se examinaron las métricas de error obtenidas sobre el conjunto de prueba considerando el Error Absoluto Medio (MAE), el Error Cuadrático Medio (RMSE), el coeficiente de determinación R^2 y el error porcentual absoluto medio (MAPE), resumidos en la tabla 3.

Tabla 3. Comparación de desempeño de modelos Predictivos(MAE, RMSE, R^2 y MAPE)

Modelo	MAE(MWh)	RMSE(MWh)	R^2	MAPE
SARIMAX	19,618.61	23,410.13	0.9871	0.8591
XGBoost	178,587.89	237,926.11	-0.3319	7.5860
LightGBM	237,692.59	297,878.36	-1.0876	10.1969

Los resultados de las evaluaciones de la aplicación de los modelos sugieren que el modelo SARIMAX fue el que obtuvo el mayor nivel de precisión, con un R^2 de 0.987, un RMSE de alrededor de 23,410 MWh y el MAPE fue inferior al 1%, lo que implica que se pudo estimar la energía disponible bastante bien. Por otro lado, los modelos de aprendizaje automático, XGBoost y LightGBM, tuvieron un rendimiento significativamente peor. En ambos modelos, las métricas de R^2 presentaron valores negativos, lo que indica una capacidad predictiva inferior a la de simplemente predecir la media de los datos de entrenamiento (una línea base ingenua), mientras que las puntuaciones de RMSE/MAPE también fueron comparativamente más altas en comparación con SARIMAX.

La diferencia que existe entre el modelo SARIMAX y los modelos de aprendizaje automático es significativamente alta. No obstante, en la revisión no se evidenciaron errores en la ejecución, en todos los modelos se entrenaron y evaluaron con los mismos datos, además de los mismos grupos de entrenamiento y prueba, y fueron utilizadas las mismas métricas, en su evaluación, el desempeño del modelo SARIMAX muestra consistencia en los pasos de preprocesamiento y validación. es evidente que los resultados muestran una gran dependencia temporal, y estacional. Circunstancias coherentes a el modelo SARIMAX y no con los otros modelos evaluados.

Esto induce a una conclusión muy clara de que, en el estudio de caso, la estructura temporal de los datos es la principal variable explicativa, y ningún método con un poder predictivo superior al de la regresión lineal puede superar significativamente las primitivas de validación temporal. Todos los valores mencionados se calcularon sobre el conjunto de prueba. Los modelos SARIMAX, XGBoost y LightGBM que se muestran más abajo, junto con todos los demás, se ajustaron utilizando el mismo esquema de validación temporal. Los valores reportados corresponden al rendimiento predictivo de cada modelo al predecir la energía mensual disponible en el sistema eléctrico.

Comparación entre valores reales y estimados

Para evaluar el desempeño de los algoritmos en la reproducción del comportamiento de una variable en estudio, se estableció una comparación directa entre las características observadas y las estimaciones producidas por cada algoritmo. En consecuencia, como se muestra en la Figura 3, se presenta la evolución temporal de la serie real y las proyecciones de puntos fuera de la muestra producidas a partir de nuestro conjunto de evaluación, de modo que las diferencias en la precisión de las predicciones puedan identificarse fácilmente.

En general, para todo el período de análisis, se verifica que, al usar únicamente la serie del modelo SARIMAX, ésta reproduce de manera muy cercana a la serie que se está analizando, siguiendo tanto su comportamiento como las tendencias y variaciones estacionales presentes en el tiempo de observación de la serie, así como los cambios bruscos. Esa cercanía muestra su potencial para capturar la topología temporal del sistema. Sin embargo, obtenemos un comportamiento completamente opuesto con los modelos XGBoost y LightGBM. En ambos casos, las predicciones se vuelven más suaves y regresan a un valor promedio, lo que indica una baja adaptabilidad para el ajuste a corto plazo ante los cambios rápidos que se muestran en la serie real. Esta característica es especialmente evidente en regímenes de alta variabilidad, donde las estimaciones de los modelos no pueden seguir el aumento explosivo y la posterior caída drástica de sus magnitudes.

En comparación, XGBoost, con respecto a LightGBM, se ajusta ligeramente, pero en ambos algoritmos existen grandes desviaciones respecto a las series observadas. A su vez, el modelo SARIMAX es más estable (más cercano a los datos reales durante un horizonte temporal más largo), lo que demuestra su mejor capacidad para representar todos los aspectos de la dinámica del sistema eléctrico analizado.




Fig. 3. Evolución temporal comparada de modelos

Evaluación en entrenamiento y prueba

Para analizar el desempeño de los modelos en cuanto a estabilidad y capacidad de generalización, se evaluaron tanto en el conjunto de entrenamiento como en el conjunto de prueba, preservando la estructura cronológica de la serie. En este sentido, la consideración de la partición temporal entre ambos conjuntos, con los valores reales comparados con los generados por el modelo SARIMAX (primera fila), XGBoost (segunda fila) y LightGBM (tercera fila), se presenta en la figura 3.

Los resultados indican diferencias claras en el comportamiento de los modelos. Para el modelo SARIMAX, el conjunto de entrenamiento y prueba se ajusta de manera consistente con alta precisión para modelar la tendencia subyacente, la estacionalidad y las variaciones locales de la serie. Este comportamiento sugiere un grado adecuado de capacidad de generalización y una comprensión correcta de la estructura temporal por parte del sistema.

El comportamiento, en cambio, es bastante diferente para los modelos de aprendizaje automático. Tanto XGBoost como LightGBM realizan un ajuste bastante estable en el conjunto de entrenamiento; sin embargo, las mismas predicciones en el conjunto de prueba se encuentran más suavizadas, acercándose a promedios, con puntuaciones más bajas debido a una adaptabilidad limitada ante cambios bruscos y fluctuaciones a corto plazo.

En comparación con LightGBM, XGBoost parece rendir ligeramente mejor, pero ambos modelos muestran una gran caída en su puntuación a partir del conjunto de entrenamiento. La diferencia indica que cuestan menos que el modelo SARIMAX dado en términos de generalización. En conclusión, los resultados muestran que, aunque los modelos de aprendizaje automático pueden explicar parte de la tendencia en el conjunto de entrenamiento, no la capturan lo suficientemente bien como para ser fiables en la predicción real. Por otro lado, SARIMAX muestra un alto grado de robustez y estabilidad y presenta un rendimiento similar para cualquiera de los dos conjuntos de datos.

Análisis de Residuos

En general, aunque en la figura 4, se observa que los residuos se agrupan alrededor de cero, sin notar ningún sesgo sistemático significativo del modelo para estimar la energía disponible. Por el contrario, durante el periodo de estudio se reconocen algunos patrones relevantes. Los residuos tienen magnitudes bajas y varianzas moderadas, especialmente durante los primeros años: posibles indicios de un buen ajuste del modelo alrededor de esta sección de la serie. Pero, durante el nuevo periodo posterior al último, también se observa de manera notable un aumento en la dispersión de los errores, lo que indica, de forma más ligera, que se está volviendo más difícil replicar todas las variaciones observadas en algunos sistemas. Además, detecta picos (positivos y negativos) en los residuos a partir de cambios de punto más abruptos de la serie. Aunque el modelo captura la forma general de patrones de eventos similares en promedio, estos picos implican que no modela eventos atípicos ni perturbaciones del sistema.

Y lo más importante, todavía se observa que las secuencias de residuos mayoritariamente positivos persisten a lo largo de algunos intervalos, lo que representa una ligera infrapredicción sistemática del modelo durante esos momentos, mientras que los valores negativos son los momentos en que la variable de medición está siendo sobrepredicha por este modelo. En resumen, el comportamiento de los residuos indica que SARIMAX ofrece un ajuste general razonable, siendo algunas estructuras de residuos solo parcialmente descritas por variables exógenas no incluidas, o debido a cambios estructurales en el sistema eléctrico.




Fig. 4. Evolución temporal de los residuos correspondientes al modelo SARIMAX

Relación entre valores reales y predicciones del modelo SARIMAX

Como se puede observar en la figura 5 la Correlación entre los puntos de datos observados y medidos y los datos modelados, respectivamente. Esta distribución predice con precisión la cantidad de energía disponible en todos los valores analizados. Sin embargo, los puntos de dispersión son más bajos y homogéneos, lo que indica que el modelo mantiene un comportamiento similar en niveles bajos y altos de la serie. Las desviaciones sistemáticas se gestionan de manera suficiente, lo que indica ausencia de sesgo. En los extremos superiores e inferiores hay una dispersión aún mayor que la que se observaría en modelos de series temporales si una variable cambiara de manera más drástica. Sin embargo, dichos cambios no tuvieron demasiada repercusión en el ajuste general del modelo. Para resumir, el análisis confirma que el modelo SARIMAX es tanto robusto como aditivo, ya que replica el comportamiento observado en la serie con un alto grado de precisión global.




Fig. 5. Relación entre los valores reales y predichos

Análisis de la función de autocorrelación (ACF) de los residuos

Se probó la independencia de los residuos del modelo SARIMAX usando la función de autocorrelación de los errores (ACF), tal como se muestra en la figura 6. La primera gráfica muestra los coeficientes de autocorrelación para varios retardos con intervalos de confianza del 95%. Se observa que los primeros retardos muestran valores de autocorrelación positiva bastante grandes, especialmente en los retardos iniciales, lo que significa que existe alguna dependencia temporal en los residuos. Sin embargo, los coeficientes para retardos mayores en su mayoría se encuentran dentro de los límites de confianza, indicando que la autocorrelación de los residuos no es significativa en estos niveles.

Esto muestra que, si bien el modelo captura gran parte de la estructura temporal de la serie, algunas dependencias a corto plazo no se han modelado completamente. Más particularmente, la autocorrelación significativa en el retardo 1, esto indica que aún queda información en el modelo ajustado y, por ello, especificamos modelos más detallados. En total, la evidencia sugiere que, aunque el ajuste general de SARIMAX es satisfactorio, la autocorrelación de los residuos en retardos bajos puede permitir un ajuste fino de los parámetros o variables explicativas adicionales.




Fig. 6. ACF de Residuos

Variables relevantes

La primera característica de importancia se evaluó para los modelos XGBoost y LightGBM, tal como se presenta en la figura 7. Con respecto al modelo XGBoost, vemos que una de las variables más importantes es la tendencia temporal (trend), la energía facturada y sus rezagos; particularmente el retazo de 12 periodos (lag_12_fact). De manera similar, la contribución de variables derivadas como medias móviles y componentes temporales parece ser moderada. Por otro lado, las variables menos importantes tienen una influencia claramente baja, mostrando muy poco impacto en el proceso predictivo.




Fig.7 Importancia de las variables en XGBoost y LightGBM

Por otro lado, esta distribución es más amplia para el modelo LightGBM; no obstante, las variables con alto peso siguen estando relacionadas con la dinámica temporal y la evolución del sistema (energía facturada, diferencia temporal (diff_12, diff_1), rezagos y componentes estacionales (month)). Algunas variables externas (por ejemplo, el índice ENSO o la interconexión) son menos relevantes o complementarias a las variables temporales de manera individual. Por lo tanto, como indican ambos modelos, si bien gran parte del poder explicativo se encuentra en variables relacionadas con la estructura temporal de la propia serie, solo puede proporcionarse una señal adicional mínima mediante la incorporación de variables externas en nuestro modelo.

Este desempeño en otros sistemas valida la hipótesis, según la cual el comportamiento temporal dentro del sistema eléctrico analizado gobierna en gran medida la dinámica del mismo; por ello, se proponen modelos con mejor desempeño, incluidos SARIMAX, que fueron diseñados específicamente para capturar este tipo de dependencia.

Proyección bajo escenarios

Pronosticar la energía facturada con un límite superior establecido por la energía disponible, lo que significa que esta cantidad no depende únicamente de la demanda, sino también de la capacidad del sistema para entregar energía. Con base en este marco, se establecieron cuatro escenarios: un escenario de referencia sin funcionamiento anómalo, un escenario de restricción de energía en el que el suministro está limitado; un escenario de alta demanda caracterizado por eventos meteorológicos extremos y cargas elevadas; y, un escenario conjuntivo que superpone condiciones de alta demanda con baja disponibilidad, tal como se muestra en la figura 8.




Fig. 8. Escenarios de predicción

Los resultados indican que, en circunstancias regulares, la energía facturada sigue la dinámica de la demanda, pero que se generan desviaciones considerables una vez que entran en juego las restricciones de disponibilidad. Esto valida que la energía facturada es una variable endógena del sistema eléctrico, determinada por factores del lado de la demanda y del suministro, lo que hace necesaria la modelación de un comportamiento no lineal.

DISCUSIÓN DE RESULTADOS

Los resultados indican que la predicción de la energía disponible en el sistema eléctrico ecuatoriano está altamente condicionada por la estructura temporal de cada serie de tiempo analizada. En este caso, el modelo SARIMAX superó a los modelos de aprendizaje automático, que no pudieron capturar la tendencia, la estacionalidad y la autocorrelación. De hecho, el alto coeficiente de determinación y los bajos errores de predicción confirman que es adecuado para representar con precisión la dinámica del sistema, este comportamiento es coherente con los trabajos previos donde modelos soportados en ARIMA/SARIMAX tienen buenos desempeños en referencia a patrones temporales y cuando la estructura estacional es la dominante [1]. Estos resultados son consistentes con estudios de pronóstico energético, demostrando que cuando los datos son periódicos, estacionales y elevada autocorrelación, SARIMAX sigue siendo competitivo con otros modelos [18].

Por otro lado, la familia de modelos basados en aprendizaje automático, como XGBoost y LightGBM, mostraron un desempeño inferior en un escenario de ese tipo. Estos modelos tienden a producir predicciones suavizadas hacia el promedio, lo que significa una baja capacidad para aprender picos pronunciados o caídas repentinas. Este comportamiento indica que la serie temporal es relativamente informativa por sí misma y, en este caso, quizá menos en las variables exógenas que consideramos, según el análisis de importancia intrínseca de las características mostrado arriba [19].

Por otro lado, el reducido número de la muestra en el orden de 300 observaciones por mensuales en total, adicionando la dependencia temporal de los datos, pudieron afectar la capacidad de generalización de los modelos de aprendizaje automático, frente a SARIMAX, lo que representa una consistencia en estudios previos [18, 19]. El análisis de los residuos de SARIMAX muestra una distribución alrededor de cero sin sesgos sistemáticos significativos, lo que confirma un buen ajuste global de SARIMAX.

Esto dicho, el hecho de que aún quede cierta autocorrelación en los primeros rezagos, significa que aún quedan patrones de corto plazo en este conjunto de datos, lo que podría ser motivo de análisis más detallado, con posibilidad de mejora. Una de las partes fundamentales del estudio es la relación existente entre la energía disponible y la energía facturada [20].

La relación entre la energía disponible y la energía facturada es una de las partes clave del estudio. Los resultados ilustran que, desde el lado de la demanda, la energía facturada no solo depende de la demanda, sino que además está condicionada por la capacidad de provisión de energía del sistema. Así, la disponibilidad de energía es una clase de restricción estructural que produce distintos regímenes observables de comportamiento asociado en el género de suficiencia y restricción [17].

Esta interpretación se establece mediante la exploración de escenarios. Sin embargo, en el caso normal, dado que la energía medida sigue la dinámica de la demanda, estas conducen a grandes desviaciones para una restricción energética miope o cuando el suministro es altamente variable. Análogamente, para escenarios con condiciones meteorológicas extremas inducidas por la demanda máxima, los modelos no logran ajustarse a los picos, ya que las no linealidades solo se reflejan parcialmente en las reglas de optimización. En conclusión, los resultados indican que es necesario un modelado inteligente para permitir que un modelo capture propiedades estructurales y que la complejidad no es simplemente fácil de modelar [8, 20].

CONCLUSIONES

Los resultados obtenidos nos llevan a concluir que la fluctuación de la energía disponible dentro del sistema eléctrico ecuatoriano se define principalmente por su estructura temporal en términos de tendencia, estacionalidad y autocorrelación. Bajo este alcance, el modelo SARIMAX fue una alternativa bien desempeñada que logró altos niveles de precisión y estabilidad en comparación con los modelos de aprendizaje automático que se evaluaron. Modelos como XGBoost y LightGBM, a su vez, presentan limitaciones porque no modelan de manera efectiva los picos y los cambios repentinos; los resultados indican un bajo desempeño cuando la información principal está dada por la propia serie, en lugar de explicarse mediante variables exógenas.

Una de las principales contribuciones de este trabajo es incorporar por primera vez una restricción de energía, donde el acceso a cierta cantidad de energía disponible condiciona el comportamiento de la energía facturada, mostrando que existen regímenes de operación a favor o en contra de la suficiencia dependiendo de si la oferta se cumple o se encuentra restringida. El análisis de escenarios confirma que, bajo condiciones normales de operación, el sistema conduce a dinámicas previsibles, mientras que en el escenario de restricción o cuando existe una demanda mayor se producen perturbaciones tan grandes que no pueden reproducirse completamente mediante los modelos. Finalmente, se evaluó la eficiencia del modelado según su capacidad para reproducir la dinámica de la operación y, para este estudio de caso, deberían preferirse los modelos tradicionales de series temporales frente a técnicas complejas.

AGRADECIMIENTO

Se agradece a la Beca de apoyo a actividades académicas de la Facultad de Posgrado de la Universidad Técnica de Manabí y al Rectorado de la Universidad Técnica de Manabí por el respaldo brindado durante el desarrollo de esta investigación. Asimismo, se reconoce el apoyo en el proceso investigativo al Grupo de Investigación Ingenierías, Integradas, Sostenibles e Inteligentes (GIISI) de la UTM y a la Red para la Integración a Gran Escala de Energías Renovables en los Sistemas Eléctricos (RIBIERSE-CYTED), cuya colaboración ha contribuido significativamente al fortalecimiento académico y técnico del presente estudio.

REFERENCIAS

- [1] Misiurek, K., *et al.* "Review of Methods and Models for Forecasting Electricity Consumption". *Energies*, 2025, vol. 18, n. 15, p. 4032. Disponible en: <https://doi.org/10.3390/en18154032>
- [2] Chen, G., *et al.* "Machine-Learning-Based Electric Power Forecasting". *Sustainability*, 2023, vol. 15, n. 14, p. 11299. Disponible en: <https://doi.org/10.3390/su151411299>
- [3] Guamán, W., *et al.* "Machine Learning-Based Projections of Long-Term Electricity Consumption: The Case Study of Ecuador". *Advanced Research in Technologies, Information, Innovation and Sustainability*, 2025, vol. 2349, p. 174-187. Disponible en: https://doi.org/10.1007/978-3-031-83432-5_12
- [4] Aslam, S., *et al.* "Machine learning applications in energy systems: current trends, challenges, and research directions". *Energy Informatics*, 2025, vol. 8, n. 1, p. 62. Disponible en: <https://doi.org/10.1186/s42162-025-00524-6>

- [5] Yang, J., *et al.* "Analysis of Weather and Time Features in Machine Learning-aided ERCOT Load Forecasting". 2024 IEEE Texas Power and Energy Conference (TPEC), College Station, TX, USA: 2024. Disponible en: <https://doi.org/10.1109/TPEC60005.2024.10472183>
- [6] Jain, A. y Gupta, S. "Evaluation of electrical load demand forecasting using various machine learning algorithms". *Front. Energy Res.* 2024, vol. 12. Disponible en: <https://doi.org/10.3389/fenrg.2024.1408119>
- [7] Akinrogunde, O., *et al.* "A systematic review of machine learning and deep learning approaches for load and energy consumption prediction in contemporary power systems". *JIMESE.* 2025, vol. 3, n. 1, p. 1-20. Disponible en: <https://doi.org/10.61511/jimese.v3i1.2025.1949>
- [8] Ye, H., *et al.* "Multi-source Data Fusion-based Grid-level Load Forecasting". *Appl. Sci.* 2025, vol. 15, n. 9. Disponible en: <https://doi.org/10.21203/rs.3.rs-5399298/v1>
- [9] Yao, Z., *et al.* "Machine learning for a sustainable energy future". *Nat Rev Mater.* 2023, vol. 8, n. 3, p. 202-215. Disponible en: <https://doi.org/10.1038/s41578-022-00490-5>
- [10] Makridakis, S., *et al.* "M5 accuracy competition: Results, findings, and conclusions". *International Journal of Forecasting.* 2022, vol. 38, n. 4, p. 1346-1364. Disponible en: <https://doi.org/10.1016/j.ijforecast.2021.11.013>
- [11] Gallo, A., *et al.* "Minería de Datos y Proyección a Corto Plazo de la Demanda de Potencia en el Sistema Eléctrico Ecuatoriano". *Revista Técnica «energía».* 2021, vol. 18, n. 1, p. 72-85. Disponible en: <https://doi.org/10.37116/revistaenergia.v18.n1.2021.461>
- [12] Maharana, K., *et al.* "A review: Data pre-processing and data augmentation techniques". *Global Transitions Proceedings.* 2022, vol. 3, n. 1, p. 91-99. Disponible en: <https://doi.org/10.1016/j.gltp.2022.04.020>
- [13] Eddaoudi, Z., *et al.* "A Brief Review of Energy Consumption Forecasting Using Machine Learning Models". *Procedia Computer Science.* 2024, vol. 236, p. 33-40. Disponible en: <https://doi.org/10.1016/j.procs.2024.05.001>
- [14] Marchand, J., *et al.* "End-to-end lifecycle machine learning framework for predictive maintenance of critical equipment". *Enterprise Information Systems.* 2025, vol. 19, n. 1-2. Disponible en: <https://doi.org/10.1080/17517575.2024.2448008>
- [15] Studer, S., *et al.* "Towards CRISP-ML(Q): A Machine Learning Process Model with Quality Assurance Methodology". *MAKE.* 2021, vol. 3, n. 2, p. 392-413. Disponible en: <https://doi.org/10.3390/make3020020>
- [16] Nooruldeen, O., *et al.* "Strategies for predictive power: Machine learning models in city-scale load forecasting". *e-Prime - Advances in Electrical Engineering, Electronics and Energy.* 2023, vol. 6. Disponible en: <https://doi.org/10.1016/j.prime.2023.100392>
- [17] Uremović, N., *et al.* "A New Framework for Multivariate Time Series Forecasting in Energy Management System". *IEEE Trans. Smart Grid.* 2023, vol. 14, n. 4, p. 2934-2947. Disponible en: <https://doi.org/10.1109/TSG.2022.3224559>
- [18] Elamin, N. y Fukushige, M. "Modeling and forecasting hourly electricity demand by SARIMAX with interactions". *Energy.* 2018, vol. 165, p. 257-268. Disponible en: <https://doi.org/10.1016/j.energy.2018.09.157>
- [19] Ashtar, D., *et al.* "Hybrid Forecasting for Sustainable Electricity Demand in The Netherlands Using SARIMAX, SARIMAX-LSTM, and Sequence-to-Sequence Deep Learning Models". *Sustainability.* 2025, vol. 17, n. 16, p. 7192. Disponible en: <https://doi.org/10.3390/su17167192>
- [20] Kachalla, I., *et al.* "Data-driven hybrid SARIMAX-MLP framework for energy consumption prediction in residential micro-grid". *Results in Engineering.* 2025, vol. 26. Disponible en: <https://doi.org/10.1016/j.rineng.2025.105336>

CONFLICTO DE INTERESES

Los autores declaran que no existen conflictos de intereses.

CONTRIBUCIÓN DE LOS AUTORES

Jesús Alberto Pérez-Rodríguez: <https://orcid.org/0000-0002-1578-2565>

Participó en el aporte de ideas, recolección de datos, revisión del estado del arte, diseño y programación de software empleado en la investigación, análisis de los resultados, redacción del borrador del artículo, revisión crítica de su contenido y aprobación final.

Leonardo Chancay-García: <https://orcid.org/0000-0002-4090-048X>

Participó en el aporte de ideas, revisión crítica del borrador del artículo y aprobación final

Mariuxi Guillen-Intriago: <https://orcid.org/0009-0005-6923-0538>

Participó en el aporte de ideas, recolección de datos, revisión crítica del borrador del artículo y aprobación final.