



## Selección multicriterio del modelo óptimo para el pronóstico de la demanda eléctrica máxima diaria considerando la satisfacción de la demanda real

### Multi-criteria selection of the optimal model for the forecast of the maximum daily electrical demand considering the satisfaction of the real demand

César Yajure-Ramírez

Universidad Central de Venezuela, Caracas, Venezuela

cyajure@gmail.com

ORCID: 0000-0002-3813-7606

doi: <https://doi.org/10.36825/RITI.13.29.004>

Recibido: Noviembre 17, 2024

Aceptado: Febrero 17, 2025

**Resumen:** Al realizar el pronóstico de la demanda eléctrica, se espera no sólo que los resultados estén cerca de la demanda real, sino que también sean iguales o superior a esta demanda. Entonces, el objetivo de esta investigación es desarrollar una metodología multicriterio para la escogencia del mejor modelo de pronóstico de la demanda eléctrica máxima diaria considerando la previsión de satisfacción de la demanda real como criterio de decisión. Se generaron modelos de pronóstico con resolución diaria y horizonte semanal, utilizando la metodología Box-Jenkins, la técnica Prophet, y la red LSTM, durante diez semanas. En cada semana se evaluaron los modelos, tanto en la etapa de prueba como al comparar el pronóstico con la demanda real, utilizando las métricas MAE, RMSE y MAPE. Para la selección del modelo óptimo de pronóstico, se utilizó la técnica multicriterio SAW, siendo las alternativas de decisión los modelos de pronósticos generados, y los criterios de decisión el MAPE global, la cantidad de veces en la que un modelo respectivo tuvo el valor mínimo del MAPE y la cantidad de días en los que la demanda pronosticada fue igual o superior a la demanda real. El mejor modelo resultó ser el correspondiente a la red LSTM con un valor de 0.926, y el modelo ARIMA fue el siguiente con un valor de 0.814.

**Palabras clave:** *Demanda Eléctrica, Modelo Óptimo, Multicriterio, Pronóstico, Suma Ponderada.*

**Abstract:** When forecasting electricity demand, it is expected not only that the results are close to the actual demand, but also that they are equal to or greater than this demand. Therefore, the objective of this research is to develop a multi-criteria methodology for the selection of the best forecast model for the maximum daily electricity demand considering the satisfaction of the real demand as a decision criterion. Forecast models were generated with daily resolution and weekly horizons, using the Box-Jenkins methodology, the Prophet technique, and the LSTM network, for ten weeks. In each week the models were evaluated, both in the testing stage and by comparing the forecast with actual demand, using the MAE, RMSE and MAPE metrics. The SAW multicriteria technique was used to select the optimal model, with the decision alternatives being the generated forecast models, and the decision criteria were the global MAPE, the number of times in which a respective model had the minimum MAPE value, and the number of days in which the forecasted demand was equal to or greater than the actual demand. The best model turned out to be the one corresponding to the LSTM network, with a value of 0.926, and the ARIMA model was next with a value of 0.814.

**Keywords:** *Electricity Demand, Optimal Model, Multi-Criteria, Forecast, Weighted Sum.*

## 1. Introducción

El horizonte de pronóstico de la demanda eléctrica define los distintos tipos de plazos utilizados en el sector eléctrico. Dependiendo de la aplicación, se podrían tener predicciones de la demanda eléctrica para el corto, mediano y largo plazo. El pronóstico de largo plazo va de un año a 20 años, y es útil para la planificación estratégica, así como para la construcción y desarrollo dentro de los subsistemas de generación, transmisión y distribución [1]. Asimismo, plantean que el pronóstico de mediano plazo va de una semana hasta un año, y se utiliza para programar el mantenimiento y planificar las compras de combustible, además de para el comercio de energía y la evaluación de ingresos de las empresas de servicios públicos. En cuanto al pronóstico de corto plazo, indican que van de una hora hasta una semana, y es muy importante para las operaciones diarias, el despacho de unidades de generación y la disponibilidad de elementos del sistema de transmisión.

De lo anterior se deduce que el pronóstico de corto plazo es de mucha utilidad desde el punto de vista operativo. Si la empresa de servicio opera en un sistema desregulado, la información se podría utilizar para estimar sus compras de energía, y así satisfacer a sus clientes. Es así como el pronóstico de la carga se ha convertido en el centro del proceso en la planificación y operación de empresas eléctricas, proveedores de energía, operadores del sistema y otros participantes del mercado eléctrico [2]. Desde otra perspectiva, sí se está en un sistema regulado, la información del pronóstico es útil en la planificación operativa de corto plazo, con el fin también de satisfacer la demanda de energía. En cualquiera de los dos casos, sería conveniente que la demanda pronosticada fuese igual o superior a la demanda real, para que así haya una previsión adecuada, y se minimice el racionamiento eléctrico. Esto evitará las pérdidas que se puedan generar en los usuarios y en las empresas proveedoras de energía, debido a la interrupción del servicio. De igual forma, sería de utilidad poder seleccionar el algoritmo más adecuado dependiendo del horizonte de pronóstico, de la data histórica disponible y del tipo de usuario, entre otros criterios.

El objetivo propuesto es desarrollar un método, basado en la toma de decisiones multicriterio, para la selección del mejor modelo de pronóstico de la demanda eléctrica máxima diaria considerando la previsión de satisfacción de la demanda real. Se consideran tres técnicas de pronóstico de la demanda: Prophet, red LSTM (*Long Short-Term Memory*) y metodología Box-Jenkins. Para evaluar los modelos se utilizan las métricas MAE (*Mean Absolute Error*), RMSE (*Root Mean Square Error*) y MAPE (*Mean Absolute Percentage Error*), tanto en la etapa de prueba como con datos nuevos utilizando el modelo respectivo, ya entrenado y probado.

## 2. Estado del arte

Luego de revisar las investigaciones previas relacionadas con el tema bajo estudio, se encontró que algunas presentan el enfoque multicriterio, pero sin tomar en cuenta la satisfacción de la demanda real como criterio de decisión. Por ejemplo, en [3] realizan el pronóstico de la demanda eléctrica de corto plazo utilizando distintos modelos de redes neuronales. Valoran los resultados de los modelos utilizando las mediciones MSE (*Mean Square Error*), RMSE y MAPE, utilizando esta última para comparar los modelos entre sí. Para un horizonte de pronóstico de un día, el modelo de red LSTM obtuvo el menor valor del MAPE con 1.01%. Comparan los resultados de los modelos desarrollados utilizando sólo la métrica MAPE, y además no hacen la selección del mejor modelo.

En [4] realizan el pronóstico de corto plazo utilizando hasta ocho técnicas diferentes, y considerando distintos tipos de clientes. Como métrica de evaluación utilizan el RMSE normalizado. Obtienen que casi todas las técnicas de pronóstico mejoran la exactitud del pronóstico cuando se comparan con el método ingenuo estacional. La técnica de bosques aleatorios tuvo el mejor desempeño cuando se trató con el cliente escolar, y con el cliente residencial, y sólo fue superado por el modelo de red neuronal en el caso del cliente supermercado. Para las categorías residencial y escolar el modelo de bosques aleatorios dio como resultado el RMSE medio más bajo (0.996 y 0.276 respectivamente) y para el conjunto de datos de supermercado el RMSE fue de 0.184. Sólo utilizan la métrica NRMSE para comparar los modelos de pronóstico desarrollados, e indican cual es el mejor modelo para cada tipo de cliente, según este único criterio.

En [5] utilizan métodos de regresión “clásicos” y algoritmos de agrupamiento para ejecutar el pronóstico de la demanda horaria para un horizonte de pronóstico de siete días. Para efectos de evaluar los modelos obtenidos, utilizan el error porcentual (PE) hora a hora. Para el caso del modelo ARIMA (*Autoregressive Integrated Moving Average*) el PE más alto fue de alrededor de 0.25% en la hora 7. El método más exacto resultó ser el de puntos

ordenados para identificar la estructura de agrupación con un PE variando entre 0% y 0.02%. No se hace una selección óptima del mejor modelo. No indican las variables explicativas utilizadas.

En [6] realizan el pronóstico de la demanda eléctrica máxima para un conjunto de 23 edificios. Utilizan modelos ARIMA, ARIMA con heterocedasticidad condicional generalizada y red neuronal artificial, con horizontes de pronóstico de una hora y un día. Para evaluar los modelos, utilizan las métricas RMSE y MAPE. Tanto para el horizonte de una hora como para el horizonte de un día, los modelos de red neuronal artificial con variables regresoras tuvieron los menores valores de MAPE con 1.87% y 6.16%, respectivamente. No seleccionan el modelo óptimo. Toman en cuenta la variable temperatura como factor externo porque el uso de aire acondicionado y calefacción afectan el valor pico de la demanda.

En [7] realizan el pronóstico de demanda eléctrica de corto plazo utilizando cuatro algoritmos para generar los modelos: Máquina de soporte vectorial, perceptrón multicapa, red LSTM y arquitectura de redes neuronales difusas. La valoración de estos modelos la realizan a través del MAPE y del coeficiente de determinación  $R^2$ . El modelo con mejor desempeño resultó ser el de máquina de soporte vectorial, tanto para un horizonte de treinta minutos, como para el horizonte de seis horas. Comparan los resultados obtenidos, pero sin seleccionar un modelo óptimo de acuerdo con las métricas utilizadas. Como variables explicativas utilizan el día, la hora y el consumo de energía retrasada desde un día hasta 25 días.

En [8] se presenta un modelo integrado que combina la descomposición por transformada ondícula, una red de función de base radial y el algoritmo de optimización del intercambio térmico para desarrollar el pronóstico de demanda eléctrica de corto plazo, y lo comparan con otros modelos de tipo estándar, utilizando las métricas MAE, RMSE y MAPE. Los resultados muestran que el modelo propuesto presenta un mejor desempeño que otras técnicas, tales como algoritmos genéticos y redes neuronales artificiales. Comparan los resultados obtenidos por los modelos para cada una de las estaciones del año, pero sin seleccionar un modelo óptimo único por estación.

En [9] utilizan la técnica de orden de preferencia por similitud con la solución ideal (TOPSIS) para seleccionar el modelo óptimo de pronóstico del consumo eléctrico residencial. Los algoritmos considerados fueron: regresión lineal múltiple, k vecinos más cercanos, máquina de soporte vectorial, árboles de decisión y red neuronal artificial. Las métricas de evaluación de modelos, que se usaron como los criterios de decisión fueron: MAE, RMSE y MAPE. El modelo óptimo de pronóstico resultó ser el de regresión lineal múltiple. No consideran como criterio, la satisfacción real de la demanda.

Asimismo, en [10] se utiliza una técnica multicriterio para escoger el modelo óptimo de predicción de la relación de desempeño de una planta solar fotovoltaica. Las alternativas del problema de decisión fueron los algoritmos de clasificación utilizados. Los criterios de decisión fueron los indicadores: exactitud, precisión, f1, recordatorio y la curva característica del receptor operativo. El modelo óptimo resultó ser el obtenido con regresión logística, con una valoración del 100%, siendo segundo el modelo de bosques aleatorios con 82.86%.

En [11], proponen un procedimiento de múltiples criterios TOPSIS con el proceso de red analítica para de escoger el modelo óptimo de pronóstico, el cual prueban utilizando un caso de estudio de un fabricante de bolsas plásticas, y considerando modelos de pronóstico relacionados con el análisis de series de tiempo. Utilizan las métricas de desempeño de modelos error medio, MAE, RMSE, MPE, RMSPE, MAPE y  $R^2$ , como criterios de decisión, y las alternativas corresponden a los modelos de pronóstico a evaluar.

En [12], utilizan el método de eliminación y elección traduciendo la realidad (Electre I) para seleccionar el conjunto de características a ser usadas en los modelos de pronóstico. Las técnicas de pronóstico comparadas fueron: red neuronal artificial, ARIMA, autorregresivos, suavizado exponencial, redes de función de base radial y aprendizaje automático. Utilizando las métricas de desempeño RMSE, MAE y MAPE, concluyen que los modelos de redes neuronales tuvieron el mejor desempeño de todos los modelos.

En el estudio presentado en [13] se hace una selección multicriterio del modelo óptimo para el pronóstico de largo plazo en Túnez, utilizando técnicas de regresión. Como alternativas de decisión se tienen a los modelos de regresión lineal múltiple, ARIMA estacional y no estacional con variables exógenas, árbol de decisión, bosques aleatorios y suavizado exponencial. Como criterios de decisión se tienen a las métricas de evaluación de modelos: ME, MAE, RMSE, MPE, MAPE, RMSPE y  $R^2$ . De las comparaciones por pares se obtiene que las mejores métricas son el MAPE, el RMSPE y el MAE. Concluyen que los mejores modelos son la regresión lineal múltiple, y el suavizado exponencial. En este trabajo pudieron descartarse previamente algunos métodos de pronóstico aplicando alguna técnica para detectar estacionalidad en los datos. Adicionalmente, los autores concluyen que hubo consistencia en el orden de importancia de los criterios, pero, sin embargo, realizan un análisis de sensibilidad con respecto a este punto, lo cual no es necesario.

Por lo anterior, se puede decir que el aporte de este trabajo consiste en el uso de la satisfacción de la demanda real como criterio de decisión en la selección del modelo óptimo de la demanda máxima diaria, haciendo uso de la técnica de comparaciones pareadas para determinar los pesos de importancia de los criterios.

### 3. Materiales y métodos

#### 3.1. Revisión teórica

##### 3.1.1. Métricas de evaluación de modelos de pronósticos

Existe una amplia variedad de métricas para la evaluación de modelos de aprendizaje automático, lo cual incluye modelos de regresión, clasificación, agrupamiento, entre otros. En [14] desarrollan un análisis exhaustivo de las métricas utilizadas para evaluar modelos en el análisis de series de tiempo. En esta investigación se trabaja con tres de ellas: MAE por ser menos sensibles a los datos atípicos, RMSE por ser muy utilizada en los métodos de optimización, y MAPE por presentar los resultados en unidades porcentuales. Plantean que el MAE es una función de pérdida simple y robusta, y se puede calcular con (1). Además, indican que el MAPE es una métrica utilizada para evaluar sistemas de pronóstico, y se puede calcular con (2). En cuanto a la métrica RMSE, postulan que toma en cuenta las variaciones del valor real, mide la magnitud promedio de los errores, y se puede calcular con (3).

$$MAE = \frac{1}{n} \sum_{k=1}^n |Y_k - F_k| \quad (1)$$

$$MAPE = \frac{1}{n} \sum_{k=1}^n \left| \left( \frac{Y_k - F_k}{Y_k} \right) \times 100 \right| \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n (Y_k - F_k)^2} \quad (3)$$

Donde:

$Y_k$ : valor real de la variable a predecir ubicado en la posición  $k$ .

$F_k$ : valor  $k$  pronosticado.

$n$ : Cantidad de valores históricos utilizables.

##### 3.1.2. Toma de decisiones multicriterio

La toma de decisiones multicriterio (MCDM) es una técnica que consiste en manejar una problemática de decisión en la que se tienen múltiples criterios de decisión a tomar en cuenta para la escogencia de la opción óptima, de un grupo de posibilidades. Esta técnica se divide a su vez en dos partes, la toma de decisiones multiobjetivo (MODM), y la toma de decisiones multiatributo (MADM). La MODM se identifica por tener un objetivo evidente y un espacio de decisión continuo, y la MADM se identifica por tener un objetivo tácito y un espacio de decisión discreto [15]. Además, según [16] un problema de decisión multiatributo se podría representar a través de su matriz de decisión. Esta es una matriz ( $M \times N$ ) en la que el elemento  $a_{ij}$  de la matriz indica la valoración de la opción  $A_i$  cuando es evaluada en términos del criterio de decisión  $C_j$ , (para  $i = 1, 2, 3, \dots, M$ , y  $j = 1, 2, 3, \dots, N$ ). Cada uno de los criterios tiene un peso de importancia relativa  $w_j$ , los que usualmente son definidos por el “tomador de decisión”. Es así como, dado un grupo de opciones y un conjunto de criterios de decisión (atributos), se desea establecer la opción óptima con el grado más alto de “deseabilidad” con respecto a los criterios de decisión. En [17] se habla de una taxonomía de problemas de decisión en la que se mencionan: la jerarquización, la

clasificación, la descripción, y la selección. Siendo este último aquel en el que la meta es seleccionar la mejor alternativa, de un conjunto de posibilidades, de acuerdo con un conjunto de criterios predeterminados.

La técnica multicriterio SAW (*Simple Additive Weighting*), también conocida como el método de la suma ponderada, es uno de los métodos de toma de decisiones más simples y utilizados [18]. Consiste en multiplicar la matriz normalizada por la matriz de pesos de importancia de los criterios, y cada fila de la matriz resultante corresponde al valor de la alternativa respectiva [19]. La matriz normalizada se obtiene dividiendo el valor mínimo para un criterio de costo entre el valor del criterio, mientras que, si el criterio es de beneficios, el valor del criterio se divide entre el valor máximo de la columna respectiva.

### 3.1.3. Técnica de comparaciones pareadas

Se basa en seleccionar un par de componentes y compararlos con respecto a una característica, sin tomar en cuenta otras características u otros elementos. Con el fin de realizar las comparaciones, Saaty propuso una escala de números que indican cuantas veces es más importante un elemento con respecto a otro elemento, según la propiedad utilizada para compararlos. La magnitud de la importancia va desde “1” hasta “9”, siendo “1” cuando los elementos tienen igual importancia y “9” cuando el elemento es extremadamente más importante con respecto al otro elemento [20]. Esta técnica fue utilizada en [21] para definir los pesos de los criterios de decisión en un problema de evaluación multicriterio para modelar factores climáticos y ambientales en la identificación de regiones áridas en el noroeste de México.

Una vez que se tiene la matriz de comparación pareadas, la ponderación de los criterios se obtiene a través de los autovectores, multiplicando al cuadrado la matriz, y a continuación, normalizando las sumas de las filas para cada elemento de la matriz y de esta forma obtener el valor del autovector [22]. Este procedimiento es repetido hasta que la discrepancia del autovector de una corrida con respecto a la siguiente no sea significativa, y en ese caso entonces, los pesos se corresponden con las componentes del autovector.

### 3.1.4. Metodología Box-Jenkins

Esta metodología se utiliza para generar los modelos ARIMA. Según lo que indican en [23], esta metodología tiene tres fases. La primera es la de identificación por medio del uso de funciones de autocorrelación y autocorrelación parcial. Luego viene la fase de estimación y diagnóstico, en la que se estiman los parámetros de los modelos potenciales, y se selecciona el mejor modelo de acuerdo con una regla específica. En la tercera fase se utiliza el modelo seleccionado, para hacer los pronósticos requeridos.

Los modelos ARIMA están compuestos por una parte autorregresiva (AR), en la que el objetivo en el instante de tiempo  $t$ , depende sus valores rezagados en el tiempo, tal como se presenta en (4), en la que se observan hasta  $p$  rezagos. La otra parte de estos modelos es la de promedios móviles (MA), en la que las variables regresoras coinciden con los errores pasados, tal como se ve en (5), en la que se presentan hasta  $q$  rezagos en los residuos.

$$Y_t = b_0 + b_1 Y_{t-1} + b_2 Y_{t-2} + \dots + b_p Y_{t-p} + e_t \quad (4)$$

$$Y_t = b_0 + b_1 e_{t-1} + b_2 e_{t-2} + \dots + b_q e_{t-q} + e_t \quad (5)$$

Al mezclar (4) y (5) se aparecen los modelos ARMA que pueden ser aplicados a series estacionarias. En caso de que la serie de interés sea no estacionaria, esta debe hacerse estacionaria previamente, diferenciándola tantas veces como sea necesario. La cantidad de veces que deba ser diferenciada dependerá de cada caso particular. El parámetro en el modelo que indica que fue diferenciada es  $I$  y el número de diferencia se denota con la letra  $d$ . Luego de aplicar la diferenciación, se consume el modelo ARIMA ( $p, d, q$ ). Asimismo, podría darse el caso de que la serie sea no estacionaria y además presente estacionalidad, entonces se deberá desarrollar un modelo que incluya estas condiciones. El modelo definitivo quedaría entonces como: ARIMA ( $p, d, q$ ) ( $P, D, Q$ ), en el que los parámetros  $P, D, y Q$ , tienen idéntico significado que las correspondientes letras en minúsculas, pero considerando los valores estacionales de los datos.

### 3.1.5. Técnica de pronóstico Prophet

Fue creada por el equipo de ciencia de datos de *Facebook* durante el año 2017, especialmente para el pronóstico de series de tiempo, apoyado en un modelo aditivo donde las tendencias no lineales se ajustan fácilmente a distintos tipos de estacionalidad, tales como: anual, semanal y diaria, además de incorporar el efecto de las vacaciones y días feriados. De acuerdo con este equipo, la técnica funciona mejor con series de tiempo que tienen características estacionales robustas y varios ciclos de datos históricos. Es firme con respecto a los datos faltantes y a los cambios en la tendencia y, usualmente, manipula bien los valores atípicos [24].

Según lo planteado por Taylor y Letham [25], la técnica se basa en un modelo de serie de tiempo compuesto por un elemento que representa a la tendencia, otro que representa a las estacionalidades, otra componente que representa el efecto de los días no laborables y finalmente el término de error. El modelo viene dado entonces por (6):

$$y(t) = g(t) + s(t) + h(t) + \epsilon_t \quad (6)$$

Donde:

$y(t)$ : es la serie temporal

$g(t)$ : es la componente de la tendencia

$s(t)$ : representa los cambios periódicos en la serie

$h(t)$ : representa el efecto de los feriados y las vacaciones

$\epsilon_t$ : es el término del residuo que simboliza los cambios que no se ajustan dentro de las otras componentes

En cuanto a la componente de la tendencia, se implementan dos tipos: modelo de saturación del crecimiento, y un modelo lineal por partes. En cuanto a la estacionalidad, esta es modelada con funciones temporales periódicas, concretamente con series de Fourier estándar, tal como la que se presenta en (7).

$$s(t) = \sum_{n=1}^N \left( a_n \cdot \cos\left(\frac{2\pi nt}{P}\right) + b_n \cdot \text{sen}\left(\frac{2\pi nt}{P}\right) \right) \quad (7)$$

Donde:

$P$ : período de la serie, que dependerá del tipo de estacionalidad

$N$ : cantidad de términos de la serie

Taylor y Letham indican que  $P$  es el período regular que esperan que la serie temporal posea, siendo igual a 7 para datos con estacionalidad semanal y 365,25 para datos con estacionalidad anual. De lo anterior se deduce que la técnica trabaja por defecto con datos con resolución diaria. Asimismo, plantean que valores más altos de  $N$  aplican a patrones estacionales que cambian más rápidamente, y en sus estudios han encontrado que un valor de 10 es útil para estacionalidades anuales, y 3 para estacionalidades mensuales. Según Peixeiro [26], la técnica define por defecto una estacionalidad de tipo aditiva, pero también se tiene la opción de establecer una estacionalidad de tipo multiplicativa. Una de las características que diferencia esta técnica de algunas otras de análisis de series de tiempo, es el manejo de los días no laborables, permitiendo la inclusión en el modelo de una lista con los días feriados y vacaciones que están dentro del período de los datos históricos, pero también dentro del horizonte de pronóstico.

### 3.2. Metodología

En la Figura 1 se presenta un bosquejo de la metodología utilizada en esta investigación, en la que se presentan algunas de las etapas propias de la ciencia de datos [27].

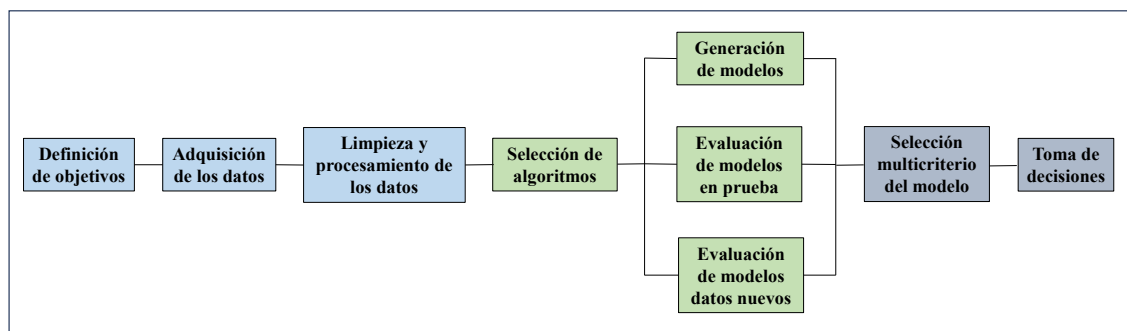


Figura 1. Esquema de la metodología empleada.

Se tienen los datos de demanda eléctrica máxima horaria para el período que va desde el primero de enero del 2021 y el veinticinco de agosto del 2024, es decir, 31,992 filas o instancias. Estos datos corresponden a la demanda horaria total de un país suramericano. A estos datos se aplican técnicas de preprocesamiento, tal como se mencionan en [28]. Estas técnicas incluyen: localización e imputación de datos faltantes, duplicados y atípicos. Luego, estos datos se llevan a resolución diaria, tomando el valor máximo ocurrido dentro de las 24 horas del día respectivo, obteniéndose un total de 1333 filas o instancias.

Para el modelado de los datos se aplican tres técnicas de pronóstico por separado: la metodología de Box-Jenkins para obtener modelos ARIMA, Prophet y la red LSTM, generándose modelos para realizar el pronóstico de la demanda eléctrica en el corto plazo, para un horizonte de siete días. Para cada modelo, se calcularon sus indicadores de evaluación, a saber: RMSE, MAE y MAPE, en la etapa de prueba del modelo respectivo. Este proceso se repitió durante diez semanas, y en cada una de ellas se comparó el pronóstico realizado con la demanda eléctrica real, calculando las métricas de desempeño de modelos de pronóstico mencionadas previamente. Asimismo, para cada semana se contabilizó la cantidad de días en los que la demanda pronosticada fue igual o superior a la demanda real. Los modelos de pronósticos fueron desarrollados utilizando las librerías del lenguaje de programación Python.

Para los modelos de red LSTM, siempre se trabajó con el 80% de los datos para el entrenamiento y 20% para la prueba. La primera capa es la red LSTM con 256 neuronas, luego una capa para regularización del 20%, seguidamente se tiene la capa de salida del tipo densa con una neurona. Se utiliza el optimizador tipo “adam” y como función de pérdida al error cuadrático medio. Se fijan 1000 épocas para el entrenamiento. Para los modelos con la técnica Prophet, se fija una estacionalidad de tipo aditiva, un intervalo de predicción del 95%, y se carga el modelo con los días no laborables tanto durante el período histórico como durante el horizonte de pronóstico. Los parámetros de los modelos ARIMA se obtienen durante la aplicación de la metodología Box-Jenkins, y pudieran diferir de modelo en modelo.

Seguidamente, se abordó un problema de toma de decisiones de múltiples criterios para la escogencia del modelo óptimo, de entre las tres alternativas utilizadas, para la predicción de la demanda eléctrica máxima. Como criterios de decisión se utilizan la métrica MAPE, obtenidos con datos nuevos cada semana, la cantidad de días en que los resultados de los pronósticos fueron iguales o superiores a la demanda real y la cantidad de semanas en que el modelo respectivo obtuvo el MAPE mínimo. Finalmente, luego de aplicar la técnica de toma de decisiones multicriterio, se selecciona el modelo óptimo para elaborar la predicción de la demanda eléctrica diaria máxima.

## 4. Resultados

### 4.1. Cálculo de los indicadores de evaluación de los modelos

Como se mencionó, las técnicas de pronóstico se aplicaron durante diez semanas, generándose tres modelos en cada una de esas semanas, y se cuantificaron los indicadores MAE, RMSE y MAPE en las etapas de prueba. Los resultados obtenidos se exhiben en la Tabla 1, de la que se puede observar que el modelo ARIMA obtuvo las mejores magnitudes de los indicadores en cada una de las diez semanas consideradas. También es importante resaltar, que el MAPE obtenido para cada modelo, en cada una de las semanas, es menor a 4%, valor que está por debajo del 5% que usualmente se toma como referencia para validar un modelo a través de esa métrica.

**Tabla 1.** Valores de métricas en etapas de prueba.

Semana	Modelo	MAE (MW)	RMSE (MW)	MAPE (%)
1	Prophet	266.37	343.88	2.26
	ARIMA	225.00	283.00	1.80
	LSTM	472.00	573.00	3.59
2	Prophet	267.00	345.00	2.26
	ARIMA	221.00	280.00	1.79
	LSTM	465.00	589.00	3.56
3	Prophet	254.00	325.00	2.12
	ARIMA	222.00	281.00	1.79
	LSTM	432.00	552.00	3.33
4	Prophet	267.00	345.00	2.25
	ARIMA	223.00	282.00	1.80
	LSTM	418.00	540.00	3.22
5	Prophet	266.00	344.00	2.25
	ARIMA	221.00	278.00	1.78
	LSTM	440.00	541.00	3.40
6	Prophet	268.00	346.00	2.26
	ARIMA	221.00	277.00	1.77
	LSTM	422.00	534.00	3.27
7	Prophet	269.00	348.00	2.27
	ARIMA	224.00	282.00	1.79
	LSTM	460.00	652.00	3.53
8	Prophet	296.00	347.00	2.27
	ARIMA	225.00	285.00	1.80
	LSTM	417.00	522.00	3.23
9	Prophet	269.00	347.00	2.27
	ARIMA	221.00	278.00	1.77
	LSTM	423.00	528.00	3.26
10	Prophet	270.00	349.00	2.28
	ARIMA	222.00	280.00	1.78
	LSTM	413.00	515.00	3.18

Fuente: Elaboración propia.

Los valores de demanda pronosticados haciendo uso de los modelos, fueron comparados con los valores reales de la demanda para el período de las diez semanas entre el 26/08/2024 y el 03/11/2024. De esta comparación se calculó nuevamente el MAPE para cada semana, y se contabilizó las semanas en las que un modelo particular tuvo el valor mínimo de la métrica (conteo 1), y la cantidad de días en los que la demanda pronosticada fue mayor o igual a la demanda real ocurrida (conteo 2). Asimismo, se calculó el MAPE global para valorar el desempeño de los modelos durante los sesenta y nueve días del período de estudio. Los resultados se muestran en la Tabla 2.

**Tabla 2.** Valores de MAPE y conteos.

Modelo	MAPE (%)	Conteo 1	Conteo 2
Prophet	4.38	3	26
ARIMA	3.78	2	30
LSTM	2.44	5	26

Fuente: Elaboración propia.

Se puede ver que el menor MAPE global corresponde al modelo de red LSTM con 2.44%, el que también tuvo la mayor cantidad de semanas, cinco de diez, con el menor MAPE. Por otra parte, el modelo ARIMA fue el que tuvo la mayor cantidad de días de demanda pronosticada igual o superior a la demanda real, con 30 de 69 días. También

se nota que el modelo Prophet tuvo el MAPE global más alto, pero quedó segundo en la cantidad de semanas con menor MAPE, y segundo en la cantidad de días con demanda pronosticada igual o superior a la demanda real.

#### 4.2. Selección multicriterio del modelo de pronóstico

Con los resultados obtenidos en el punto anterior, se diseña un problema de toma de decisiones de múltiples criterios para la escogencia del mejor modelo de pronóstico. En esta investigación, se utiliza la técnica multicriterio SAW. En la investigación de [9] hacen uso de la técnica TOPSIS para la selección del mejor modelo de pronóstico del consumo de energía eléctrica residencial.

Las alternativas de decisión de nuestro problema son los tres modelos de pronóstico considerados, mientras que los criterios de decisión corresponden al MAPE global y a los conteos realizados. El primer paso de la técnica SAW consisten en obtener la matriz normalizada, la cual se obtiene a partir de los valores de la Tabla 2, y se muestra en la Tabla 3.

Tabla 3. Matriz normalizada.

Alternativas	Criterios de decisión		
	MAPE	Conteo 1	Conteo 2
Prophet	0.558	0.600	0.867
ARIMA	0.646	0.400	1.000
LSTM	1.000	1.000	0.867

Fuente: Elaboración propia.

Para obtener la magnitud de cada alternativa, se requiere conocer previamente los pesos de importancia relativa de los criterios de decisión, lo cual se consigue aplicando alguna técnica de ponderación de criterios de decisión. En el trabajo [29] se lleva a cabo la comparación de cuatro técnicas de ponderación de criterios de decisión, incluyendo la técnica de comparaciones pareadas, la cual es la que es usada en la presente investigación.

Los pesos de importancia relativa se presentan en la Figura 2. Se puede notar que la suma de los tres pesos es igual a la unidad. Asimismo, se observa que el conteo de los días en los que la demanda pronosticada es igual o mayor a la demanda real obtuvo un peso del 56%, contra un 32% para el MAPE global, y un 12% para el conteo del MAPE semanal mínimo. Para la matriz de comparaciones pareadas utilizadas se obtuvo un índice de consistencia de sólo el 1.6%, por debajo del 10%, considerado como el valor máximo permitido [30].

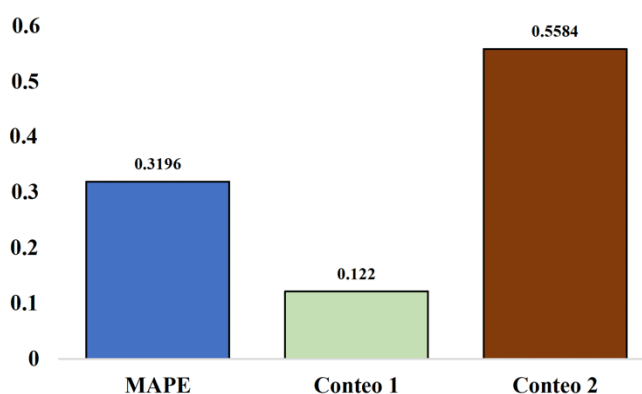


Figura 2. Pesos de los criterios de decisión.

Luego, se multiplican la matriz normalizada, y los pesos de importancia relativa, obteniendo las magnitudes de cada una de las alternativas consideradas. Los resultados, organizados de mayor a menor, se presentan en la Figura 3.

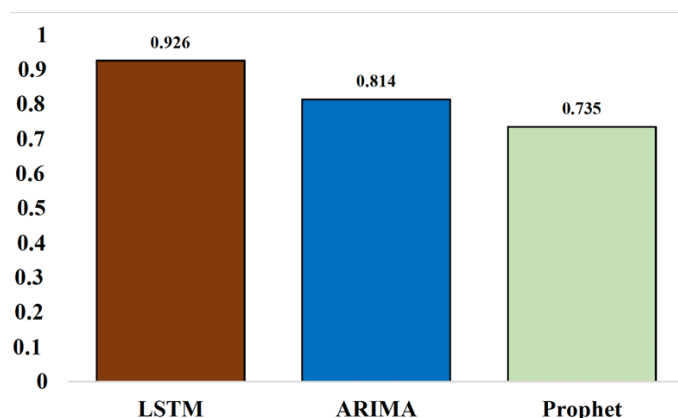


Figura 3. Puntaje de alternativas de decisión.

La técnica multicriterio aplicada indica que se selecciona la alternativa que tenga la magnitud más alta, de lo cual se deduce que el modelo óptimo para realizar el pronóstico de la demanda máxima eléctrica diaria es el correspondiente a la red LSTM, siendo la satisfacción real de la demanda el criterio de decisión más importante.

## 5. Conclusiones

Se presentó una metodología multicriterio para la escogencia del mejor modelo de predicción de la demanda eléctrica máxima diaria considerando la metodología Box-Jenkins para generar modelos ARIMA, la técnica Prophet para el análisis de series de tiempo, y el modelo de red LSTM. Como criterios de decisión se consideraron el MAPE global utilizando datos fuera de los conjuntos de entrenamiento y prueba, la cantidad de veces que el modelo respectivo tuvo el valor mínimo del MAPE semanal, y la cantidad de días en las que la demanda pronosticada fue igual o superior a la demanda real.

Los valores de las métricas obtenidos en la etapa de prueba del modelo, arrojó que los tres modelos tuvieron siempre un MAPE inferior al 5%, y el modelo ARIMA siempre generó el MAPE mínimo con un valor menor al 2%. El segundo mejor modelo, según esa métrica y etapa de prueba, fue el modelo obtenido con la técnica Prophet. Al comparar la demanda pronosticada con la demanda real para el período de estudio de diez semanas, se obtuvo un MAPE global mínimo de 2.44% para el modelo de red LSTM, y de 3.78% y 4.38% para los modelos ARIMA y Prophet, respectivamente. Con el modelo ARIMA la demanda pronosticada tuvo la mayor cantidad de días siendo igual o superior a la demanda real.

Con la técnica de comparaciones pareadas, se pudo asignar un peso de importancia relativa a los criterios de decisión, siendo el principal de ellos el conteo de los días en los que la demanda pronosticada es igual o mayor a la demanda real con un peso del 56%, seguido del MAPE global con un 32%. Luego al aplicar el método multicriterio de suma ponderada, se obtuvieron valores para cada alternativa de decisión, lo cual permitió jerarquizarlas, y hacer la selección del modelo de red LSTM como el óptimo para desarrollar la predicción de la demanda eléctrica máxima diaria, con una puntuación de 0.926.

Para efectos de verificar la robustez de la metodología propuesta, se recomienda replicar el trabajo realizado considerando la resolución horaria del pronóstico y tomando en cuenta otras técnicas de análisis de series de tiempo, así como también algoritmos de aprendizaje automático.

## 6. Referencias

- [1] Hammad, M. A., Jereb, B., Rosi, B., Dragan, D. (2020). Methods and Models for Electric Load Forecasting: A Comprehensive Review. *Logistics, Supply Chain, Sustainability and Global Challenges*, 11 (1), 51-76. <https://doi.org/10.2478/jlst-2020-0004>
- [2] Weron, R. (2006). *Modeling and Forecasting Electricity Loads and Prices - A Statistical Approach*. John Wiley & Sons Ltd.

- [3] Islam, B., Ahmed, S. (2022). Short-Term Electrical Load Demand Forecasting Based on LSTM and RNN Deep Neural Networks. *Mathematical Problems in Engineering*, 1-10. <https://doi.org/10.1155/2022/2316474>
- [4] Groß, A., Lenders, A., Schwenker, F., Braun, D., Fischer, D. (2021). *Comparison of short-term electrical load forecasting methods for different building types*. 10th DACH+ Conference on Energy Informatics. <https://energyinformatics.springeropen.com/articles/10.1186/s42162-021-00172-6>
- [5] Filipova-Petrakieva, S., Dochev, V. (2022). Short-Term Forecasting of Hourly Electricity Power Demand. *Engineering, Technology & Applied Science Research - Regresion and Cluster Methods for Short-Term Prognosis*, 12 (2), 8374-8381. <https://etasr.com/index.php/ETASR/article/view/4787/2711>
- [6] Kim, Y., Son, H.-g., Kim, S. (2019). Short term electricity load forecasting for institutional buildings. *Energy Reports*, 5, 1270–1280. <https://doi.org/10.1016/j.egyr.2019.08.086>
- [7] Jales Melo, J. V., Soares Lira, G. R., Guedes Costa, E., Leite Neto, A. F., Oliveira, I. B. (2022). Short-Term Load Forecasting on Individual Consumers. *Energies*, 15 (16), 1-16. <https://doi.org/10.3390/en15165856>
- [8] Khan, S. (2023). Short-Term Electricity Load Forecasting Using a New Intelligence-Based Application. *Sustainability*, 15 (16), 1-12. <https://doi.org/10.3390/su151612311>
- [9] Yajure-Ramírez, C. A. (2023). Multi-criteria methodology based on data science for the selection of the optimal forecast model for residential electricity consumption. *Scientia et Technica*, 28 (3), 108-116. <https://doi.org/10.22517/23447214.25335>
- [10] Yajure Ramírez, C. A. (2023). Selección del modelo óptimo de predicción de la relación de desempeño de una planta solar fotovoltaica. Un enfoque multicriterio basado en algoritmos de aprendizaje automático. *Ciencia, Ingenierías y Aplicaciones*, 6 (2), 7-29. <https://doi.org/10.22206/cyap.2023.v6i2.2935>
- [11] Badulescu, Y., Hameri, A.-P., Cheikhrouhou, N. (2021). Evaluating demand forecasting models using multi-criteria decision-making approach. *Journal of Advances in Management Research*, 18 (5), 661-683. <https://doi.org/10.1108/JAMR-05-2020-0080>
- [12] Deina, C., Ferreira dos Santos, J., Biuk, L., Lizot, M., Converti, A., Valadares Siqueira, H., Trojan, F. (2023). Forecasting Electricity Demand by Neural Networks and Definition of Inputs by Multi-Criteria Analysis. *Energies*, 16 (4), 1-24. <https://doi.org/10.3390/en16041712>
- [13] Koubaa, Z., El-Amraoui, A., Frikha, A., Delmotte, F. (2024). Multicriteria Decision Making for Selecting Forecasting Electricity Demand Models. *Sustainability*, 16 (21), 1-15. <https://doi.org/10.3390/su16219219>
- [14] Jadon, A., Patil, A., Jadon, S. (2022). A Comprehensive Survey of Regression Based Loss Functions for Time Series Forecasting. *ArXiv*, 1-13. <https://doi.org/10.48550/arXiv.2211.02989>
- [15] Eltarabishi, F., Omar, O., Alsyouf, I., Bettayeb, M. (2020). *Multi-Criteria Decision Making Methods And Their Applications – A Literature Review*. International Conference on Industrial Engineering and Operations Management. Dubai, UAE. <http://www.ieomsociety.org/ieom2020/papers/656.pdf>
- [16] Triantaphyllou, E., Shu, B., Nieto Sanchez, S., Ray, T. (1998). Multi-Criteria Decision Making: An Operations Research Approach. En J. G. Webster (Ed.) *Encyclopedia of Electrical and Electronics Engineering* (pp. 175-186). John Wiley & Sons. [https://bit.csc.lsu.edu/trianta/EditedBook\\_CHAPTERS/EEEE1.pdf](https://bit.csc.lsu.edu/trianta/EditedBook_CHAPTERS/EEEE1.pdf)
- [17] Ishizaka, A., Nemery, P. (2013). *Multi-Criteria Decision Analysis - Methods and Software*. John Wiley & Sons, Ltd.
- [18] Taherdoost, H. (2023). Analysis of Simple Additive Weighting Method (SAW) as a Multi-Attribute Decision-Making Technique: A Step-by-Step Guide. *Journal of Management Science & Engineering Research*, 6 (1), 21-24. <https://doi.org/10.30564/jmser.v6i1.5400>
- [19] Sahoo, B., Behera, R., Pattnaik, P. (2022). A Comparative Analysis of Multi-Criteria Decision Making Techniques for Ranking of Attributes for e-Governance in India. *International Journal of Advanced Computer Science and Applications*, 13 (3), 65-70. <https://dx.doi.org/10.14569/IJACSA.2022.0130311>
- [20] Saaty, T. L. (2008). Decision making with the analytic hierarchy process. *International Journal of Services Sciences*, 1 (1), 83-98. <https://dx.doi.org/10.1504/IJSSCI.2008.017590>
- [21] López Osorio, R., Pérez Aguilar, L., Zambrano Medina, Y., Ávila Aceves, E. (2024). Aplicación de evaluación multicriterio para modelar factores climáticos y ambientales en la identificación de regiones áridas en el noroeste de México. *Revista de Investigación en Tecnologías de la Información*, 12 (28), 54-70. <https://doi.org/10.36825/RITI.12.28.006>

- [22] Gómez-Romero, J., Soto Flores, R., Garduño Román, S. (2019). Determination of the Weightings of Hydroelectric Sustainability Criteria by Combining AHP and GP Extended Methods. *Ingeniería*, 24 (2), 116-142. <https://doi.org/10.14483/23448393.14469>
- [23] Box, G., Jenkins, G., Reinsel, G., Ljung, G. (2016). *Time Series Analysis - Forecasting and Control*. John Wiley & Sons, Inc.
- [24] Prophet. (2024). *Quick Start Python API*. [https://facebook.github.io/prophet/docs/quick\\_start.html#python-api](https://facebook.github.io/prophet/docs/quick_start.html#python-api)
- [25] Taylor, S., Letham, B. (2017). Forecasting at Scale. *PeerJ Preprints*. <https://doi.org/10.7287/peerj.preprints.3190v2>
- [26] Peixeiro, M. (2022). *Time Series Forecasting in Python*. Manning Publications Co.
- [27] Cielen, D., Meysman, A., Ali, M. (2016). *Introducing Data Science*. Manning Publications Co.
- [28] Navlani, A., Fandango, A., Idris, I. (2021). *Python Data Analysis*. Packt Publishing Ltd.
- [29] Yajure Ramírez, C. (2016). Comparación de técnicas de ponderación de criterios en metodologías de toma de decisiones multicriterio aplicadas a la jerarquización de tecnologías renovables. *Revista Tecnológica ESPOL*, 29 (2), 12-27. <https://rte.espol.edu.ec/index.php/tecnologica/article/view/463>
- [30] Papathanasiou, J., Ploskas, N. (2018). *Multiple Criteria Decision Aid - Methods, Examples and Python Implementations*. Springer Nature Switzerland AG.