



REICIT



Revista Especializada de Ingeniería  
y Ciencias de la Tierra

VOL: 5 N° 1 Julio - Diciembre 2025  
ISSN L: 2805-1874

---

## Sobre Redes Neuronales y el Pronóstico de Cargas en Sistemas de Generación y Distribución Eléctrica, Panamá, 2010

### On Neural Networks and Load Forecasting in Electric Generation and Distribution Systems, Panama, 2010

Jorge Luis Martinez Ramirez  
Universidad de Panamá, Facultad de Ingeniería, Panamá  
jorgel.martinez@up.ac.pa  
<http://orcid.org/0000-0002-1036-6167>

Jose Simmonds  
Universidad de Panamá, Facultad de Ingeniería, Panamá  
jose.simmonds@up.ac.pa  
<https://orcid.org/0000-0001-6180-3497>

DOI <https://doi.org/10.48204/reicit.v5n1.7684>

**Recibido: 9/2/2025 Aceptado: 10/6/2025**

#### RESUMEN

El presente trabajo aborda el pronóstico de cargas en redes de distribución eléctrica mediante una metodología que no se limita a una sola variable, sino que selecciona y analiza múltiples variables relacionadas con la predicción de carga, utilizando datos viables en escenarios de red reales. Se proponen diversas líneas de investigación futuras, como la integración de la metodología en sistemas de tiempo real para monitorear variables de red y generar pronósticos horarios, así como la incorporación de sistemas inteligentes que respondan automáticamente a interrupciones y permitan consultas sobre datos históricos y factores de carga. Además, se sugiere mejorar los modelos mediante técnicas como redes MLP, algoritmos genéticos para optimizar parámetros de redes neuronales, y la aplicación conjunta de modelos neuronales y transformadas wavelet para filtrar ruido en series de



datos y mejorar la precisión de las predicciones. Estas propuestas buscan incrementar la eficacia y aplicabilidad de la metodología en entornos operativos reales.

**PALABRAS CLAVE:** Pronóstico de cargas, métodos de pronósticos, redes neuronales, series temporales, técnicas de inteligencia artificial.

## ABSTRACT

This paper addresses load forecasting in electrical distribution networks using a methodology that is not limited to a single variable, but rather selects and analyzes multiple variables related to load prediction, using viable data from real-world network scenarios. Several future lines of research are proposed, such as the integration of the methodology into real-time systems to

monitor network variables and generate hourly forecasts, as well as the incorporation of intelligent systems that automatically respond to outages and allow queries on historical data and load factors. Furthermore, it is suggested that the models be improved using techniques such as MLP networks, genetic algorithms to optimize neural network parameters, and the joint application of neural models and wavelet transforms to filter noise in data series and improve prediction accuracy. These proposals seek to increase the effectiveness and applicability of the methodology in real-world operating environments.

**KEY WORDS:** Load forecasting, forecasting methods, neural networks, time series, artificial intelligence techniques.

## INTRODUCCIÓN

El correcto funcionamiento de una compañía de generación de energía requiere modelos matemáticos precisos para el pronóstico de la carga eléctrica. Estos modelos facilitan la toma de decisiones sobre la compra y generación de energía, la administración de la carga de conmutación y la planificación de infraestructura. Además, son fundamentales para proveedores de energía, organizaciones de estándares internacionales (ISO), instituciones financieras y otros actores en los mercados de generación, transmisión y distribución de electricidad. El pronóstico de carga se clasifica en tres tipos según el horizonte temporal: corto plazo (PCCP), que abarca de una hora a una semana; mediano plazo (PCMP), que cubre de una semana a un año; y largo plazo (PCLP), que se extiende más allá de un año. Cada categoría de pronóstico cumple funciones específicas dentro de la planificación y operación de las compañías eléctricas.

Desde la perspectiva del sistema de energía eléctrica, las cargas pueden clasificarse en tres grupos funcionales:

Cargas domiciliarias



Cargas industriales

Cargas comerciales

Estas cargas presentan características muy distintas entre ellos con relación al tamaño, simetría ( $1\Phi$  o  $3\Phi$ ), constancia de la carga y el período de funcionamiento.

La precisión del pronóstico varía según el horizonte temporal. A corto plazo, se puede estimar la carga del día siguiente con un margen de error de 1-3%, mientras que predecir la carga pico de un año en adelante es más complejo debido a la falta de pronósticos meteorológicos precisos a largo plazo. Para estos casos, se utilizan distribuciones probabilísticas basadas en datos históricos y la denominada carga meteorológica normalizada, calculada a partir del promedio de condiciones climáticas características de la carga pico en un periodo de 25-30 años.

Dado que factores como fluctuaciones en la oferta y demanda, condiciones meteorológicas y precios de la energía pueden impactar significativamente la red eléctrica, el pronóstico de cargas resulta esencial. Su aplicación en el corto plazo permite gestionar los flujos de carga, prevenir sobrecargas y mejorar la confiabilidad del sistema, reduciendo fallos y apagones. Además, influye en la evaluación de contratos y productos financieros vinculados a los precios de la energía. En un mercado des-regulado, los pronósticos a largo plazo justifican inversiones en infraestructura y ajustes tarifarios.

Los métodos de pronóstico incluyen técnicas estadísticas (TE) y de inteligencia artificial (IA), como regresión lineal (RL), redes neuronales (RN), lógica difusa (LD) y sistemas expertos (SE). Para el mediano y largo plazo, se emplean modelos econométricos y de uso final, mientras que en el corto plazo se utilizan enfoques como días similares, modelos de series temporales y algoritmos de aprendizaje estadístico. La precisión del pronóstico depende tanto de la calidad de las técnicas utilizadas como de la exactitud de los escenarios meteorológicos proyectados.

Aunque el pronóstico del clima queda fuera del alcance de este estudio, se reconoce el avance de modelos computacionales como el MM5, desarrollado por un consorcio de universidades (Dudhia, 2014; Dudhia & Bresch, 2002; Skamarock et al., 2018; Skamarock et al., 2012; Weber & Mass, 2019).

Por lo posteriormente mencionado, el objetivo de esta publicación es demostrar que el algoritmo de las redes neuronales resulta mejor en realizar la tarea de pronóstico de carga eléctrica en un conjunto de datos en particular. Este enfoque se justifica por la capacidad de las redes neuronales para capturar patrones complejos y no lineales en los datos, lo que las convierte en una herramienta poderosa para mejorar la precisión en el pronóstico de cargas eléctricas.

**CONFIGURACIÓN EXPERIMENTAL.** En las redes de distribución eléctrica se generan numerosas estadísticas cuyo análisis podría ayudar a abordar problemas como la demanda y las pérdidas de



carga en los sistemas de generación y distribución. Uno de estos desafíos es la predicción de carga, que se complica por la naturaleza distribuida de los dispositivos y la diversidad de servicios ofrecidos, dificultando la selección y pronóstico de variables relacionadas con los niveles de uso. En este trabajo, utilizando un conjunto de datos particular, proponemos una metodología basada en paradigmas de Inteligencia Artificial para resolver este problema.

## Proceso de adquisición del conocimiento

La minería de datos (Data Mining, en inglés) facilita la aplicación de algoritmos, como redes neuronales, árboles de decisión, lógica difusa y algoritmos genéticos, a los vastos datos generados en la industria eléctrica, permitiendo descubrir conocimiento oculto. Sin embargo, aunque los algoritmos son cruciales, la adquisición de conocimiento va más allá de estructuras de datos y técnicas avanzadas; estas deben aplicarse en las áreas y datos adecuados. Este proceso es un ciclo iterativo de aprendizaje que mejora las soluciones con el tiempo (Ahlemeyer-Stubbe & Coleman, 2014; Linoff & Berry, 2011; Shmueli et al., 2017).

La Figura 1 muestra un círculo íntegro de un proceso de adquisición de conocimiento en un ambiente de la industria eléctrica, cuyas etapas son cuatro:

1. **Identificar el problema.** En esta etapa se identifican los dominios en que el análisis de los datos puede tener algún valor significativo.

En el sector eléctrico, este paso implica analizar diversos datos de la red (consumo de clientes, variables temporales, climáticas, magnitud de carga y flujos de potencia) y orientarlos según el problema a resolver, como:

- ⇒ Analizar estadísticas de generación y distribución para resolver el problema de predicción de carga.
- ⇒ Estudiar la caracterización de la carga, esto es clave para una gestión adecuada de la demanda.
- ⇒ Utilizar datos de clientes para estudios de mercado o identificación de perfiles.

Estas estadísticas pueden obtenerse de:

- ⇒ Dispositivos de medición en redes reales.
- ⇒ Estaciones o subestaciones de generación y distribución.
- ⇒ Centros meteorológicos.

Estos datos permiten analizar y predecir la carga en redes de distribución. Sin embargo, usarlos directamente como entradas en un modelo de predicción puede generar errores significativos o incluso impedir la predicción. Para evitarlo, es necesario procesar la información y darle una representación adecuada según el modelo de predicción empleado.



**2. Transformar los datos en información.** Esta etapa de la metodología utiliza técnicas artificiales para transformar datos en información útil, extrayendo características representativas mediante su análisis. Estas técnicas se clasifican según el procesamiento aplicado a los datos en:

1. Limpieza de datos: Se elimina ruido, se corrigen inconsistencias y se detectan valores atípicos. Por ejemplo, valores infinitos pueden reemplazarse por el promedio de los datos.

2. Integración de datos: Se combinan datos de múltiples fuentes (bases de alarmas, estadísticas de hardware, simuladores) para resolver redundancias. Técnicas como las correlaciones de Pearson y Spearman facilitan este proceso.

3. Transformación de datos: Los datos se adaptan para su uso en minería de datos mediante normalización, suavizado, agregación, generalización o estandarización. Por ejemplo, modelos no lineales pueden linealizarse aplicando transformaciones a las variables (Linoff & Berry, 2011).

Otro ejemplo sería normalizar los valores de una variable en los rangos de 0 a 1 o de -1 a 1 (ver ANEXO, Cuadro 4).

4. Reducción de datos. Las técnicas de reducción de datos buscan simplificar la representación de los datos sin comprometer su integridad. Ejemplos incluyen operaciones de agregación para construir cubos de datos y la detección de variables irrelevantes mediante algoritmos como C4.5 (Cervantes et al., 2018; Weiss, 2003; Weiss, 2009; Xu et al., 2014).

La estadística de un dispositivo en la red de distribución se considera una variable del sistema. La transformación de datos aplica técnicas artificiales a las  $m$  variables de red para seleccionar las  $n$  que mejor representen la información, como se muestra en la Figura 2.

Dado el cambio constante en las fluctuaciones de carga, las estadísticas pueden presentar inconsistencias y ruido, por lo que es necesario limpiar y estandarizar los datos antes de usarlos como entrada en un modelo de predicción.

Además, el gran número de variables obtenidas de la red puede incluir redundancias o irrelevancias que no contribuyan a la predicción. Para resolver esto, se aplican técnicas de correlación y selección, reduciendo el número de variables de  $m$  a  $n$ , donde  $n < m$ .

Finalmente, una vez seleccionadas y estandarizadas las variables, se elige un modelo de predicción adecuado.

**3. Transformar la información en conocimiento.** Esta transformación se realiza aplicando técnicas de minería de datos. Es decir, aplicar técnicas como RN, árboles de decisión, clustering o algoritmos genéticos a un conjunto de datos de entrada para obtener patrones o relaciones entre ellos.



La información se considera a las variables seleccionadas y estandarizadas, estas variables son entrada de un modelo de predicción el cual llevará a cabo la transformación de esta información en conocimiento. Esta transformación consiste en predecir el valor de una variable dependiente basándose en los valores de un conjunto de variables independientes. El conocimiento obtenido será la predicción de la carga a una, dos, tres días o horas, ver Figura 2.

Además, el problema de predicción puede abordarse utilizando técnicas como árboles de decisión, redes neuronales (RN) o algoritmos genéticos.

**4. Transformar el conocimiento en inteligencia.** Esta fase implica seleccionar patrones relevantes y analizar los resultados para integrar el conocimiento obtenido en un sistema experto. El objetivo es interpretar y comprender dicho conocimiento, que en muchas aplicaciones se utiliza para que el sistema experto (Weiss, 1999; Weiss & Hirsh, 1998a, 1998b) pueda resolver problemas de forma automática. Esta capacidad de aplicar el conocimiento adquirido es lo que se considera inteligencia.

### **Pronóstico de cargas en sistemas de generación y distribución eléctrica**

El proceso de adquisición de conocimiento, como se mencionó antes, es un ciclo de cuatro etapas, cada una con varios pasos. Identificar un problema implica recopilar datos, transformarlos en información usando técnicas de inteligencia artificial, y luego convertir esa información en conocimiento eligiendo el algoritmo de predicción adecuado según el tipo de datos. Interpretar los resultados no se limita a medir el error, sino a verificar si cumplen con lo esperado. Esta sección propone una metodología para analizar estadísticas de una red eléctrica y resolver el problema de pronóstico de carga usando inteligencia artificial.

La metodología no solo busca resolver el pronóstico, sino que también genera resultados parciales que ayudan a entender el comportamiento de la red. Los pasos son:

1. Recolección de datos: Obtener estadísticas (series de tiempo) que describan el comportamiento de la red de generación y distribución.
2. Preparación y limpieza de datos: Asegurar que los datos estén listos para su análisis.
3. Selección de variables no redundantes: Analizar la correlación entre variables para eliminar redundancias.
4. Selección de variables relevantes: Descartar variables irrelevantes para la predicción.
5. Pronóstico de variables: Predecir series de tiempo basadas en las variables seleccionadas.
6. Predicción del objetivo (carga de la red): Predecir la carga usando las variables pronosticadas.
7. Interpretación y evaluación de resultados: Analizar y validar los resultados del modelo predictivo.

Como se muestra en la Figura 3, la metodología no es lineal, sino recursiva. Si un paso no cumple con los resultados esperados, es necesario retroceder para hacer ajustes. Por ejemplo, si el modelo tiene un error alto, puede ser necesario modificar sus propiedades o revisar las variables seleccionadas. Este enfoque iterativo asegura que el proceso se adapte y mejore continuamente.



## Colecta de datos en un escenario de red de generación y distribución

El objetivo de este experimento fue analizar las estadísticas de carga en un sistema de generación y distribución eléctrica. Para ello, se diseñó, implementó y evaluó un modelo de red neuronal (RN) con capacidad predictiva, basado en inteligencia artificial, comparándolo con métodos estadísticos tradicionales. Cada estadística generada por el sistema se consideró como una variable de red.

La recopilación de datos sobre la carga eléctrica y la variable climática (temperatura) fue un proceso complejo. La mayoría de las bases de datos públicas ofrecen esta información en promedios mensuales o anuales, mientras que las empresas privadas, aunque registran datos detallados, suelen ser reacias a compartirlos. Tras una extensa búsqueda, se obtuvieron datos horarios y diarios de carga eléctrica del Centro de Despacho de la Autoridad del Canal de Panamá (ACP), que opera en la zona del canal.

La obtención de las series climáticas (temperatura) también presentó desafíos, principalmente por la necesidad de datos horarios y su correspondencia geográfica con los datos de carga. Finalmente, esta información se consiguió a través de la sección de Hidrología y Meteorología de la ACP.

## Preparación y limpieza de los datos

El segundo paso de la metodología consiste en asegurar la consistencia de los datos. El problema principal radicaba en que algunas muestras de las series temporales de datos meteorológicos (velocidad y dirección del viento, radiación solar, temperatura y humedad) presentaban valores faltantes o indefinidos, debido al alto nivel de desagregación de estas series.

Para solucionar este problema se utilizó el programa WEKA Workbench (software de minería de datos. <https://ml.cms.waikato.ac.nz/weka/>), en donde todas las muestras de la serie de tiempo que no tuvieran un valor definido o que presentaran data faltante en la serie se insertaba un valor constante igual a cero.

Mediante la eliminación de ruido en los datos, se puede obtener la siguiente información sobre las variables que componen la serie temporal:

1. Identificación del tipo de variables: determinar si son unarias, binarias, nominales, ordinales o de intervalo.
2. Cálculo de medidas estadísticas: obtener el valor mínimo, máximo, media y desviación estándar para cada variable.
3. Representación gráfica: visualizar la distribución de las variables.



4. Transformación de variables: crear nuevas variables a partir de las existentes, como una variable binaria derivada de una variable de intervalo.

No obstante, este análisis estadístico solo proporciona información individual sobre cada variable de la serie temporal, sin revelar las relaciones o dependencias entre ellas.

### Selección de variables no significativas

Identificar variables que contengan toda la información necesaria o que no aporten nada relevante en aplicaciones como bases de datos puede optimizar el uso del espacio en disco. En redes de telecomunicaciones, detectar variables redundantes permite reducir el número de elementos a analizar para entender el comportamiento del sistema completo. Además, esto facilita la recopilación de datos en situaciones reales.

Para llevar a cabo la correlación de Spearman entre  $m$  variables de la serie de tiempo, se utilizó el lenguaje de programación estadístico R versión 4.3.3 y Visual Studio Code versión 1.89 como la IDE (Ambiente de Desarrollo Integrado) para la implementación de los códigos que generasen una matriz de correlación de  $m \times m$  valores.

La elección de variables no redundantes se realiza así:

Se fija un umbral  $u$  para identificar correlaciones fuertes entre las variables.

Si el valor de correlación  $v_{i,j}$  entre las variables  $i$  y  $j$ , supera el umbral  $u$ , se considera que existe una alta correlación, por lo que sólo una de las dos variables debe incluirse en el conjunto de variables no redundantes. Por otro lado, si  $v_{i,j}$  no supera el umbral  $u$ , se considera una baja correlación, y ambas variables pueden incluirse en dicho conjunto.

En el caso de que el valor de correlación  $v_{k,j}$  entre las variables  $k$  y  $j$ , no supere el umbral  $u$ , antes de añadirlas al conjunto de variables no redundantes, es necesario verificar que no estén ya incluidas.

Tras este análisis de correlación, se obtiene el conjunto de variables no redundantes. Finalmente, es importante analizar la relación entre estas variables y la variable que se desea predecir.

### Selección de variables para la predicción

El rendimiento de una red eléctrica puede verse influenciado por diversas variables, como el consumo de los clientes, la carga de trabajo en las unidades de despacho, el factor de carga, el factor de simultaneidad, el factor de coincidencia, la demanda máxima y mínima, la temperatura, la humedad, entre otros. Sin embargo, para este estudio, se ha seleccionado como variable principal a predecir el



nivel de utilización de los servicios de generación y distribución eléctrica, ya que el objetivo es comprender mejor la carga del sistema.

Es importante destacar que, entre las variables no redundantes, pueden existir algunas irrelevantes que no contribuyen a la predicción de la variable objetivo. Además, un número elevado de variables de entrada puede afectar negativamente los modelos de predicción. Por un lado, cuantas más variables se incluyan, mayor será el riesgo de sobreentrenamiento el modelo y de aumentar el volumen de datos de entrenamiento. Por otro lado, en modelos basados en redes neuronales, un mayor número de variables puede dificultar la optimización de los pesos. Este desafío en la selección de variables es común en análisis estadísticos, y los árboles de decisión son una herramienta útil para identificar las variables más relevantes (Linoff & Berry, 2011).

El propósito de la selección de variables no se limita únicamente a reducir el número de entradas del modelo, sino también a identificar aquellas que sirvan como indicadores confiables de los cambios en los niveles de carga. Tras el análisis de selección de variables en relación con el objetivo, se determinan las variables que serán utilizadas como entradas en el modelo de predicción.

### **Pronóstico de las variables seleccionadas.**

El modelo de predicción tiene como objetivo principal utilizar  **$n$  variables de entrada** para generar **una salida**. En la Cuadro 1 se muestra un ejemplo de cómo se organizan los datos para esta tarea. Cada fila representa un caso, donde las columnas corresponden a los valores de las  **$n$  variables independientes**, y la última columna indica la **variable dependiente**, que es el valor que el modelo intenta predecir. En este caso de estudio, la salida del modelo es el valor predicho, como se ilustra en la Figura 2. Así, basándose en los valores de las variables de entrada en un momento  **$t$** , el modelo puede estimar el valor del **target** en ese mismo momento. Sin embargo, el verdadero desafío es predecir el valor del **target** en un momento futuro  **$t+1$** . Para lograrlo, es necesario pronosticar primero los valores de las variables de entrada en  **$t+1$** , como se ejemplifica en la Cuadro 2, para un modelo con  **$n$  entradas** y un **target** de salida.

El pronóstico de estas variables puede realizarse mediante un modelo de regresión lineal. Además, un modelo **VAR** (vector autoregresivo) puede implementarse utilizando una red **neuronal tipo**



**perceptrón**. La Figura 4 muestra la arquitectura de un perceptrón con  $n$  **unidades de entrada** y  $n$  **variables de salida** que se desean pronosticar.

El entrenamiento de una red neuronal perceptrón implica usar como datos de entrada los valores de las variables en un momento  $t-1$  (ver Cuadro 2) y como salida, su pronóstico en el momento  $t$  (ver Cuadro 3). Los valores del **target  $i$**  en el modelo de pronóstico son los mismos que los de la **variable de entrada  $i$** , pero desplazados una unidad de tiempo. De esta manera, después del entrenamiento, cuando la red reciba los valores de las variables en el momento  $t$ , podrá predecir su valor en  $t+1$ .

Este modelo, basado en una red neuronal perceptrón, no solo permite pronosticar un conjunto de variables para usarlas como entrada en un modelo de predicción, sino que también puede ayudar a analizar el comportamiento futuro de variables en una red de distribución eléctrica.

### **Predicción de carga**

El modelo de predicción se basó en una red neuronal con arquitectura de perceptrón multicapa (MLP, por sus siglas en inglés). La Figura 4 ilustra su estructura general, que incluye  $n$  **unidades de entrada** (variables independientes), una capa oculta y una única variable de salida (variable dependiente).

El entrenamiento de la red MLP utiliza como entrada los valores de las variables en el tiempo  $t+1$  y genera como salida la predicción del objetivo (target) en el mismo tiempo  $t+1$ . Este enfoque permite predecir la carga diaria. Además, se identificaron las variables relacionadas con el target, lo que en un escenario real permitiría recopilar datos de estas variables para predecir la carga futura con un perfil horario, aplicable a cualquier día de la semana (lunes a domingo).

### **Interpretación de los resultados.**

Una red se entrena reduciendo una función de error (también conocida como criterio de estimación). Muchas de estas funciones se basan en el principio de máxima probabilidad, que depende de una familia de distribuciones de error (ruido). Para variables de intervalo, se suele emplear la distribución normal, también llamada criterio de error cuadrático medio. Este enfoque es común cuando los objetivos tienen una distribución de ruido normal con varianza constante.



El objetivo es encontrar una red que funcione bien con datos nuevos. La forma más sencilla de comparar diferentes redes neuronales es evaluar la función de error utilizando datos independientes a los usados en el entrenamiento. Varias redes se entrenan minimizando una función de error definida sobre el conjunto de entrenamiento. Luego, su rendimiento se compara evaluando la función de error en un conjunto de validación independiente, seleccionando la red con el menor error en estos datos.

Para evaluar las predicciones del modelo, es necesario calcular la diferencia entre el valor pronosticado y el valor real. Para ello, se utilizan diversas métricas de error.

### Suma de los errores cuadráticos

$$SSE = \sum_{t=1}^n (y_t - \hat{y}_t)^2$$

### Error cuadrático medio

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2$$

### Raíz del error cuadrático medio

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}$$

### Donde:

- $y_t$  es la salida (valor del pronóstico),
- $\hat{y}_t$  es el valor real,
- $n$  es el número de muestras.

## RESULTADOS Y DISCUSIÓN

**Estudio de Caso** Se presenta un escenario de un sistema eléctrico de potencia para ilustrar la aplicación de la metodología propuesta en esta iniciativa. Dicha metodología consiste en una serie de pasos diseñados para predecir la carga en sistemas de generación y distribución eléctrica. En esta sección, se aplicarán estos pasos a un caso de estudio basado en un escenario de red de datos comunes en empresas del sector eléctrico (Ausmus et al., 2019; Figueiredo et al., 2005; Schuelke-Leech et al., 2015).

### Colectar los datos en un escenario de sistema eléctrico de potencia



Se recopilan datos estadísticos generados en las unidades de despacho de una red eléctrica. Esta red opera en el centro de despacho de la ACP y se basa en una topología de mediciones que incluye lecturas de carga horarias, diarias y mensuales, correspondientes al período de enero a diciembre de 2007.

### **Preparación y limpieza de los datos**

El procesamiento de los datos se lleva a cabo sobre la serie de tiempo construida. El primer paso consiste en identificar y corregir ruido e inconsistencias en los datos. Se resolvió el problema de valores y variables no definidos utilizando Excel y R. En los Cuadros 5 y 6 se presenta una sección de la serie de tiempo antes y después de aplicar el escalado lineal (**Linear Scaling**) entre **-1** y **+1**, como parte de la preparación y limpieza de los datos.

Para el análisis estadístico de las variables de la serie de tiempo, se empleó la herramienta WEKA Workbench, que incluye diversas bibliotecas para limpiar, explorar y analizar datos, así como para desarrollar y validar modelos de Minería de Datos y el Aprendizaje de Máquinas.

No obstante, el análisis estadístico solo proporciona información sobre el uso de la red, sin revelar las relaciones o dependencias entre las distintas variables.

### **Selección de variables no significativas**

Tras asegurar la consistencia de los datos, se procedió al análisis de variables en la serie temporal. El primer paso fue identificar un conjunto de variables no significativas, con el objetivo de reducir su número sin comprometer la calidad de los datos. Para resolver este problema, se empleó la **correlación de Spearman** y un modelo basado en **árboles de decisión**.

Se utilizó el lenguaje estadístico R para calcular la correlación de Spearman entre las cinco variables de la serie temporal: velocidad del viento, dirección del viento, temperatura, humedad y radiación solar. Como resultado, se generó una **matriz de 365x365**.

En la simulación, se analizó la estadística de uso de toda la red de datos. Tras el análisis de correlación, se descartaron las variables con índices de correlación insignificantes, seleccionando únicamente aquellas relevantes para el modelo.

### **Selección de variables para la predicción**

La selección de las variables relacionadas con la carga se realizó mediante un análisis de correlación y un árbol de decisiones. Para ello, se utilizó WEKA Workbench, que incluye una herramienta específica para crear árboles de decisiones, como se observa en la Figura 5. Este modelo consta de dos componentes principales:



1. Conjunto de datos: Contiene las 18 variables previamente seleccionadas. WEKA Workbench facilita la importación y exportación de estos datos.
2. Árbol de decisiones: Este componente genera el árbol basándose en el criterio de división elegido, permitiendo analizar y visualizar las relaciones entre las variables.

Este enfoque simplifica el proceso de identificación de las variables más relevantes para la carga.

### **Pronóstico de variables seleccionadas e interpretación de resultados**

Como se mencionó antes, solo contamos con datos hasta el momento  $t$ . Para predecir la variable objetivo (el target) en el tiempo  $t+1$ , necesitamos los valores de las 18 variables de entrada en ese mismo instante. Dado que estos datos no están disponibles al momento de la predicción, utilizamos un modelo VAR para pronosticar los valores de siete (7) de estas variables en  $t+1$ . Este modelo se basa en los valores pasados de las propias variables y de las demás. O sea, que es posible desarrollar un modelo VAR utilizando una Red Neuronal Perceptron, como se muestra en la Figura 4. En este caso, las 18 variables seleccionadas son la entrada del modelo VAR en el tiempo  $t$ , y la salida es el valor de la variable de carga eléctrica en el tiempo  $t+1$ .

El modelo consta de cinco componentes principales:

1. Conjunto de datos: Incluye las 18 variables previamente seleccionadas.
2. División de datos: Dos tercios de los datos se usaron para entrenar el modelo, mientras que el tercio restante se destinó a la validación. Para realizar esta división, se utilizó la herramienta WEKA Data Miner, que permite particionar los datos de manera aleatoria dentro del conjunto total. Sin embargo, es importante destacar que el orden temporal de las muestras no se altera, ya que se trata de una serie temporal.

### **Pronóstico de la carga (i+1)**

La predicción se realizó utilizando tres modelos para estimar la carga esperada del día siguiente ( $i+1$ ). La selección de las variables se basó en modelos previos, siguiendo la metodología de conclusiones e interdependencias establecidas. El modelo de pronóstico para un día es el siguiente:

$$Carga_{(i+1)} = F \left( \text{Mes}, \text{Día\_semana}, \text{TempMax}_{(i)}, \text{TempMax}_{(i-1)}, \text{TempMax}_{(i-2)}, \text{TempMax}_{(i-3)}, \right. \\ \left. \text{TempMin}_{(i)}, \text{TempMin}_{(i-1)}, \text{TempMin}_{(i-2)}, \text{TempMin}_{(i-3)}, \text{TempMed}_{(i)}, \text{TempMed}_{(i-1)}, \text{TempMed}_{(i-2)}, \right. \\ \left. \text{TempMed}_{(i-3)}, \text{Carga}_{(i)}, \text{Carga}_{(i-1)}, \text{Carga}_{(i-2)}, \text{Carga}_{(i+1)} \right)$$

Tras la limpieza, depuración y predicción de las variables de entrada, se trabajó con un conjunto de 361 observaciones. A partir de estas, se construyó una matriz con 18 variables de entrada y se identificó una carga de salida ( $i+1$ ). Los datos se dividieron en dos grupos después de su limpieza y



preparación: los primeros 241 conjuntos se utilizaron para el aprendizaje, y los 120 restantes se destinaron a la validación (ver Cuadro 7).

### **Pronóstico de la carga (i+1) con el Modelo M5P de Weka**

Primero, se construyó un "modelo de árbol" utilizando el clasificador M5P en la herramienta Weka. Se evaluaron los datos con dos enfoques: en el primero, se impidió la poda del árbol, mientras que en el segundo se permitió. En el Cuadro 8 se detallan los parámetros seleccionados para cada caso, y en el Cuadro 9 se muestran los resultados del modelo M5P sin poda (izquierda) y con poda (derecha).

El modelo de árbol podado mostró una mayor precisión ( $R = 0.777$ ) en comparación con el modelo árbol sin podar ( $R = 0.077$ ). Ambos modelos presentaron errores significativos ( $RMSE = 57.904$  y  $3054.982$ , respectivamente), resultados que coinciden con los hallazgos de Maskey [REF 27]. Además, el árbol podado es más sencillo de interpretar que el no podado (Figura 6), reduciendo el número de reglas de 131 a 4. Aunque existe una ligera diferencia en el tiempo de procesamiento entre ambos modelos (1.4 y 1.04 segundos), esta podría considerarse irrelevante.

### **Pronóstico de la carga (i+1) con el Modelo MLP de Weka y MATLAB**

Se utilizaron tanto Weka como MATLAB para desarrollar el modelo MLP con el fin de predecir la carga (i + 1). En el Cuadro 10 se detallan los parámetros de la red neuronal MLP empleados en ambas herramientas para configurar el modelo.

Durante el entrenamiento, es posible ajustar los parámetros de aprendizaje, siendo los más críticos las funciones ocultas y la tasa de aprendizaje. Las Figuras 7 y 8 ilustran el modelo MLP implementado en Weka y MATLAB, respectivamente.

Al comparar los errores de las dos técnicas, específicamente la raíz del error cuadrático medio (RMSE) tras las ejecuciones (Figuras 9 y 10), se observa que el modelo PCM en Weka fue ligeramente menos preciso ( $R = 0.796$ ) que el desarrollado en MATLAB ( $R = 0.816$ ). Además, el error en Weka fue mayor ( $RMSE = 57.533$ ) en comparación con el de MATLAB ( $RMSE = 39.959$ ), que resultó significativamente menor. Esta diferencia en la magnitud del error podría deberse a que MATLAB ejecuta el algoritmo PCM más rápido, ya que utiliza la "tasa de aprendizaje del descenso por el gradiente", lo que permite un control más preciso de los cuatro parámetros y optimiza el tiempo de calibración frente a la "tasa de aprendizaje adaptativo" empleada en Weka. Cabe destacar que lograr resultados consistentes en ambos modelos no es sencillo, por lo que se requieren criterios más estrictos para alcanzar los mismos resultados.

### **Pronóstico de la carga (i+1) con el Modelo FBR de Weka y MATLAB**



El modelo FBR se configuró ajustando el número de clusters (grupos de aprendizaje) en ambos enfoques. Tras varios intentos de prueba y error, se determinó que el mejor valor constante de clusters para Weka fue 7, mientras que en MATLAB se estableció un valor constante de 15500 para el parámetro spread (ancho) de la función de base radial, cuyo valor por defecto es 1.0. Estos ajustes permitieron normalizar los datos.

Se observó que, al modificar estos parámetros, los resultados fueron más precisos en MATLAB (Figura 11), con un error menor (RMSE = 34.065) en comparación con Weka (Figura 12; RMSE = 88.142). Estas diferencias son significativas, ya que el objetivo es minimizar el error. A pesar de ello, los resultados obtenidos con MATLAB fueron altamente aceptables tanto en el entrenamiento como en la verificación, como se mencionó anteriormente.

En cuanto a la FBR (Función de Base Radial), MATLAB mostró un coeficiente de correlación notablemente mayor ( $R = 0.760$ ) en los datos de prueba, mientras que Weka obtuvo un valor menos significativo ( $R = 0.332$ ). Además, se evidenció que el modelo Weka tuvo dificultades para simular los picos en la gráfica de verificación (Figura 11).

### **Comparación con otros modelos**

Tras completar las fases de entrenamiento y validación, se compararon los resultados de los modelos implementados en Weka y MATLAB (árbol M5P, red neuronal (RN) y función de base radial (FBR)) con otros algoritmos disponibles en estas plataformas (ver Figuras 13 y 14). El objetivo era evaluar en qué medida las redes neuronales superan a otros métodos como herramienta de modelado y predicción. Para ello, se analizaron los siguientes modelos:

- Regresión Lineal: Incluye la regresión lineal simple, expresada como  $y = mx + b + \epsilon$ .
- Redes Elman: Se utilizó un modelo con la estructura [10 1].

Los resultados de esta comparación se resumen en el Cuadro 11.

Como se muestra en la Figura 11, el  $R^2$  del modelo neuronal con Weka es ligeramente inferior al obtenido con la regresión lineal simple en términos de ajuste, pero resulta más eficaz en la predicción. Además, el Cuadro indica que el algoritmo Elman tuvo un  $R^2$  menos preciso que ambos métodos, aunque presentó el menor error. Esto podría deberse a que las variables que explican la evolución de la demanda eléctrica en el tiempo están relacionadas de manera no lineal. Al utilizar modelos lineales, como la regresión lineal, se ignora la parte no lineal del fenómeno, lo que genera un error significativo en el ajuste. En cambio, las redes neuronales (RN), al emplear funciones de transferencia no lineales, permiten capturar estas relaciones no lineales, lo que mejora la capacidad del modelo para representar la dinámica del fenómeno estudiado.



## CONCLUSIONES Y RECOMENDACIONES

### *Conclusiones*

Las técnicas de inteligencia artificial, especialmente la minería de datos, han demostrado ser efectivas para resolver problemas en redes de distribución eléctrica, permitiendo el pronóstico de series temporales y la predicción de variables de carga. Este estudio propone una metodología para predecir la carga en sistemas de generación y distribución eléctrica, aplicable incluso sin ser experto en el sector.

La metodología transforma estadísticas descriptivas del comportamiento de la carga en conocimiento predictivo sobre la red. Se emplearon técnicas como la correlación de Spearman para identificar variables no redundantes y árboles de decisión para seleccionar las más relevantes. Para el pronóstico, se utilizó un modelo vector autoregresivo basado en una red neuronal Perceptrón, y una red MLP para la predicción de carga, demostrando su eficacia en el caso de estudio. Finalmente, se integraron los resultados en un escenario real de generación y distribución.

Además, se destacó la influencia de variables climatológicas, como la temperatura, y factores temporales en la curva de carga eléctrica, aunque la relación exacta con la demanda sigue siendo compleja, asemejándose a una "caja negra" que procesa entradas para generar salidas ajustadas a ciertos criterios.

### *Recomendaciones*

La metodología propuesta tiene la ventaja de no basar el pronóstico de carga en una sola variable, sino en un proceso de selección de variables relacionadas con la predicción, utilizando datos viables en un escenario de red real.

Entre las posibles líneas de investigación derivadas de este trabajo, destacan:

1. Integración en tiempo real: Implementar la metodología en un sistema para monitorear constantemente las variables de red seleccionadas, ya sea mediante hardware o software, para predecir la carga en los puntos de compra de empresas eléctricas. Esto permitiría obtener pronósticos horarios para cualquier día futuro.
2. Sistemas inteligentes: Incorporar los valores de predicción en un sistema automatizado que responda ante interrupciones en el suministro, permitiendo consultas sobre datos históricos, factores de carga, demanda máxima/mínima, entre otros.
3. Mejora de modelos: Durante el desarrollo de la metodología, se podrían explorar modelos basados en redes MLP o combinar técnicas de selección para reducir el error en la validación de datos.



4. Optimización con algoritmos genéticos: Dada la incertidumbre en los parámetros de la red neuronal (unidades ocultas, tasa de aprendizaje, etc.), se podría estudiar su optimización mediante algoritmos genéticos, reduciendo el riesgo de mínimos locales en el entrenamiento.
5. Uso de transformadas wavelets: Investigar la aplicación conjunta de modelos neuronales y transformadas wavelet para filtrar ruido en series de datos, permitiendo predicciones más precisas sobre la evolución del fenómeno estudiado.

Estas propuestas buscan mejorar la precisión y aplicabilidad de la metodología en escenarios reales.

## AGRADECIMIENTO

Queremos agradecer a los colaboradores de la sección de energía y al personal de la Sección de Hidrología y Meteorología de la Autoridad del Canal de Panamá (ACP) por su apoyo brindado al suministrar la data necesaria para el desarrollo de este trabajo. Finalmente, al Ingeniero Javier Acosta por todo el apoyo brindado, consejos y sugerencias respecto al tema de la generación de energía eléctrica.

## REFERENCIAS BIBLIOGRÁFICAS

- Ahlemeyer-Stubbe, A., & Coleman, S. (2014). *A practical guide to data mining for business and industry*. John Wiley & Sons.
- Ausmus, J., de Carvalho, R. S., Chen, A., Velaga, Y. N., & Zhang, Y. (2019). Big data analytics and the electric utility industry. 2019 international conference on smart grid synchronized measurements and analytics (SGSMA),
- Cervantes, B., Monroy, R., Medina-Pérez, M. A., Gonzalez-Mendoza, M., & Ramirez-Marquez, J. (2018). Some features speak loud, but together they all speak louder: A study on the correlation between classification error and feature usage in decision-tree classification ensembles. *Engineering Applications of Artificial Intelligence*, 67, 270-282.
- Dudhia, J. (2014). A history of mesoscale model development. *Asia-Pacific Journal of Atmospheric Sciences*, 50, 121-131.
- Dudhia, J., & Bresch, J. F. (2002). A global version of the PSU-NCAR Mesoscale Model. *Monthly Weather Review*, 130(12), 2989-3007.
- Figueiredo, V., Rodrigues, F., Vale, Z., & Gouveia, J. B. (2005). An electric energy consumer characterization framework based on data mining techniques. *IEEE Transactions on power systems*, 20(2), 596-602.
- Linoff, G. S., & Berry, M. J. (2011). *Data mining techniques: for marketing, sales, and customer relationship management*. John Wiley & Sons.



- Schuelke-Leech, B.-A., Barry, B., Muratori, M., & Yurkovich, B. (2015). Big Data issues and opportunities for electric utilities. *Renewable and Sustainable Energy Reviews*, 52, 937-947.
- Shmueli, G., Bruce, P. C., Yahav, I., Patel, N. R., & Lichtendahl Jr, K. C. (2017). *Data mining for business analytics: concepts, techniques, and applications in R*. John Wiley & Sons.
- Skamarock, W. C., Duda, M. G., Ha, S., & Park, S.-H. (2018). Limited-area atmospheric modeling using an unstructured mesh. *Monthly Weather Review*, 146(10), 3445-3460.
- Skamarock, W. C., Klemp, J. B., Duda, M. G., Fowler, L. D., Park, S.-H., & Ringler, T. D. (2012). A multiscale nonhydrostatic atmospheric model using centroidal Voronoi tessellations and C-grid staggering. *Monthly Weather Review*, 140(9), 3090-3105.
- Weber, N. J., & Mass, C. F. (2019). Subseasonal weather prediction in a global convection-permitting model. *Bulletin of the American Meteorological Society*, 100(6), 1079-1089.
- Weiss, G. M. (1999). Timeweaver: A genetic algorithm for identifying predictive patterns in sequences of events. Proceedings of the 1st Annual Conference on Genetic and Evolutionary Computation-Volume 1,
- Weiss, G. M. (2003). *The effect of small disjuncts and class distribution on decision tree learning*. Rutgers The State University of New Jersey, School of Graduate Studies.
- Weiss, G. M. (2009). The impact of small disjuncts on classifier learning. In *Data mining: Special issue in annals of information systems* (pp. 193-226). Springer.
- Weiss, G. M., & Hirsh, H. (1998a). Learning to predict rare events in categorical time-series data. International Conference on Machine Learning,
- Weiss, G. M., & Hirsh, H. (1998b). Learning to Predict Rare Events in Event Sequences. KDD,
- Xu, Z., Kusner, M. J., Weinberger, K. Q., Chen, M., & Chapelle, O. (2014). Classifier cascades and trees for minimizing feature evaluation cost. *The Journal of Machine Learning Research*, 15(1), 2113-2144.