

## **METODOLOGÍA PARA LA ESTIMACIÓN DE CONSUMO ELÉCTRICO DE EMBARCACIONES CON TECNOLOGÍAS DE ELECTROMOVILIDAD EN EL TRANSPORTE FLUVIAL EN COLOMBIA**

**Sanabria Vargas O.A<sup>1</sup>, Vergara Pestana H.D<sup>1</sup>, Mendoza R.R<sup>1</sup>, Paipa Sanabria E.G<sup>1</sup>**

<sup>1</sup>Grupo de Diseño e Ingeniería-COTECMAR  
e-mail: osanabria@cotecmar.com

### **RESUMEN**

En el marco del proyecto FerroFluvial 4.0 el cual tiene como objetivo formular un plan de investigación para la para la evaluación y priorización de tecnologías de electromovilidad en el sector férreo y fluvial, es necesario conocer el consumo eléctrico de las embarcaciones que posean tecnologías orientadas hacia la electromovilidad para así estimar los impactos energéticos futuros que tendría la implementación de estas soluciones en el sector fluvial sobre la matriz energética del país. Este estudio tiene como objetivo determinar una metodología de estimación de consumos eléctricos de diferentes sistemas de movilidad fluvial, teniendo en cuenta tipo de transporte, tecnologías de operación y variables exógenas asociadas a condiciones de navegabilidad en el territorio colombiano. Se realizó una revisión bibliográfica de las metodologías aplicadas para estimaciones de consumo eléctrico en diferentes sectores a nivel mundial basadas en métodos estadísticos, inteligencia artificial, entre otros, que sirvió para definir la metodología basada en lógica difusa para la estimación del consumo eléctrico. El modelo busca minimizar el error de estimación de consumo eléctrico de embarcaciones fluviales con electromovilidad a través de un preprocesamiento y pronóstico de datos de embarcaciones con similares características, tipo de transporte y tecnologías de operación. Para la implementación de alternativas tecnológicas de electromovilidad es crucial estimar la magnitud del impacto energético que puede sufrir la red nacional referente a estaciones de carga requeridas en puertos, muelles y embarcaderos.

**Palabras Clave:** Electricity Consumption Forecast, Fuzzy logic, ARIMA, TBATS, ANN, LSTM.

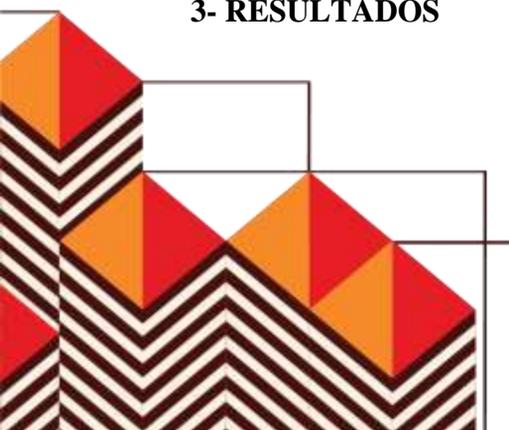
## 1- INTRODUCCIÓN

Le previsión de consumo eléctrico ha sido una tarea clave en la industria eléctrica durante muchos años debido a su impacto tanto en la economía como en la planeación, operación, mantenimiento de los sistemas eléctricos [1] y también a su utilidad para garantizar una operación estable y eficaz de los sistemas de energía a futuro. En el marco del proyecto FerroFluvial 4.0 para la incursión de electromovilidad en el sector fluvial, esta investigación tiene como objetivo determinar una metodología para la estimación de consumos eléctricos en embarcaciones con sistemas de electromovilidad teniendo en cuenta tipo de transporte, tecnologías de operación y variables exógenas asociadas. Como información de entrada para la caracterización de consumos eléctricos de diferentes sistemas de movilidad fluvial se realiza una revisión bibliográfica de las metodologías aplicables para pronosticar el aumento del consumo eléctrico y se analizan los parámetros de entrada y salida, casos de uso y errores estimación de los diferentes métodos.

## 2- MATERIALES Y MÉTODOS

La revisión del estado del arte de diferentes metodologías aplicables para pronosticar el aumento de consumo eléctrico en diferentes casos fue necesaria para llevar a cabo esta investigación. En la revisión se analizaron diferentes casos de aplicaciones donde se aplican modelos de series temporales, modelos basados en inteligencia artificial, modelos basados en regresiones y métodos de lógica difusa, también se revisaron parámetros de entrada, salida, variables exógenas relacionadas, porcentajes de error y/o niveles de efectividad de las metodologías utilizadas para los diferentes casos revisados.

## 3- RESULTADOS



A partir de la revisión del estado del arte se logró identificar 7 tipos de metodologías utilizadas para la estimación y/o pronósticos de variables relacionadas a la demanda eléctrica, que se describen a continuación:

### **AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA)**

En la Tabla 1 se describe la definición general, algunas aplicaciones de esta metodología de estimación y sus resultados en función de los errores tenidos en cuenta en cada aplicación.

Tabla 1. Definición y aplicaciones ARIMA.

	Definición	Aplicaciones y errores
ARIMA	El modelo autorregresivo integrado de promedio móvil (ARIMA) permite describir un valor como una función lineal de datos anteriores y errores aleatorios, pero también puede contener un componente cíclico o estacional [2]. Es decir, debe contener todos los elementos necesarios para describir el fenómeno. Este se desarrolla integrando dos formas diferentes de regresiones lineales, la Autorregresiva (AR) y la Media Móvil (MA) añadiendo una diferenciación de la serie indicada por la letra I (integración) [3].	<ol style="list-style-type: none"> <li>1. Pronóstico del consumo de energía hidroeléctrica para Pakistán utilizando modelos ARIMA y análisis de oferta y demanda para el año 2030 [4]. Diferencia <math>\pm 1.6\%</math> respecto a datos reales.</li> <li>2. Pronóstico del consumo y la producción de electricidad en hogares inteligentes mediante métodos estadísticos [5]. MAE<sup>1</sup>: 198,27 Watts respecto a datos reales.</li> <li>3. Aplicación del enfoque de modificación residual en ARIMA estacional para el pronóstico de la demanda de electricidad: un estudio de caso de China [6]. MAPE<sup>2</sup>: 24.24%, 16.8% y 34.44% respecto a datos reales</li> </ol>

### **Error de predicción:**

Los resultados de la **Error! No se encuentra el origen de la referencia.** para el pronóstico de consumo eléctrico en Pakistán, basado en ARIMA, realizado en [4] indican que los datos estimados siguen de manera acertada los datos de consumo reales para el periodo de 2001 a 2010.

<sup>1</sup> Error Medio Absoluto (MAE-Mean Absolute Error): permite establecer el desempeño de un pronóstico. Fuente: [46].

<sup>2</sup> Error Absoluto Medio Porcentual (MAPE-Mean Absolute Percentage Error): es un indicador del desempeño del Pronóstico que mide el tamaño del error (absoluto) en términos porcentuales. Fuente: [47].

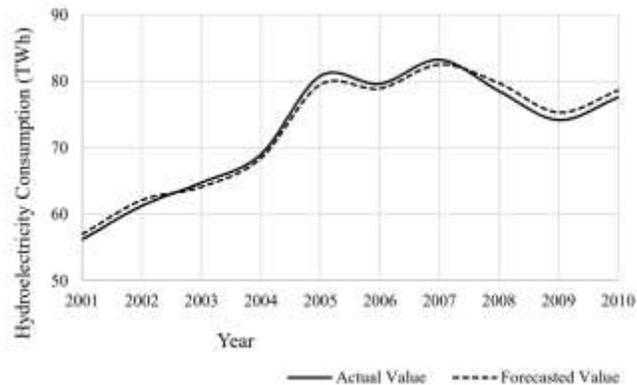


Figura 1. Pronóstico de consumo de hidroelectricidad en Pakistán con ARIMA. Fuente: [4]

**TBATS.**

En la Tabla 2 se describe la definición general, algunas aplicaciones de esta metodología de estimación y sus resultados en función de los errores tenidos en cuenta en cada aplicación.

Tabla 2. Definición y aplicaciones TBATS

	Definición	Aplicaciones y errores
TBATS	<p>TBATS es una metodología de estimación que proporciona un pronóstico preciso para series de tiempo con estacionalidades complejas [12]. Este modelo permite modelizar múltiples estacionalidades, aunque por contra, no permite añadir regresores o variables independientes [7]. Como curiosidad, el acrónimo del modelo viene de:</p> <p>T (Trigonometric regressors): regresores trigonométricos para múltiples estacionalidades.                      B (Box-Cox transformations): transformación de Box-Cox, para corregir el defecto de normalidad en los datos.                      A (ARMA errors): modelización de los errores del ARMA.                      T (trend): tendencia.                      S (seasonality): estacionalidad.</p>	<ol style="list-style-type: none"> <li>1. Rendimiento de series de tiempo para la demanda de carga de electricidad en Johor [8]. TBATS RMSE<sup>3</sup>: 7368.679 respecto a datos reales.</li> <li>2. Pronóstico de la demanda de carga de vehículos eléctricos utilizando modelos de series de tiempo [9]. TBATS RMSE &gt; 8%</li> <li>3. Previsión del precio de la electricidad en el mercado diario danés utilizando los métodos TBATS, ANN y ARIMA [10]. TBATS MAE: 37.51</li> </ol>

<sup>3</sup> RMSE: Error cuadrático medio (RMSE) mide la cantidad de error que hay entre dos conjuntos de datos. [46]

**Error de predicción:**

En el pronóstico representado en la **¡Error! No se encuentra el origen de la referencia.2**, tres métodos de estimación fueron implementados para el pronóstico del precio de la electricidad en el mercado danés durante los primeros 212 días de 2017 [10]; Para este se tomaron los precios de la electricidad del año anterior (2016) con el objetivo de entrenar los modelos. En la Figura 2 se aprecia que la previsión del modelo TBATS para el periodo analizado no sigue los picos de los datos reales en algunos puntos, resultando este el segundo modelo con el error medio más alto (37.5) después de ARIMA con un error de 33.24 puntos y antes de ANN con un error de 41.41 puntos.

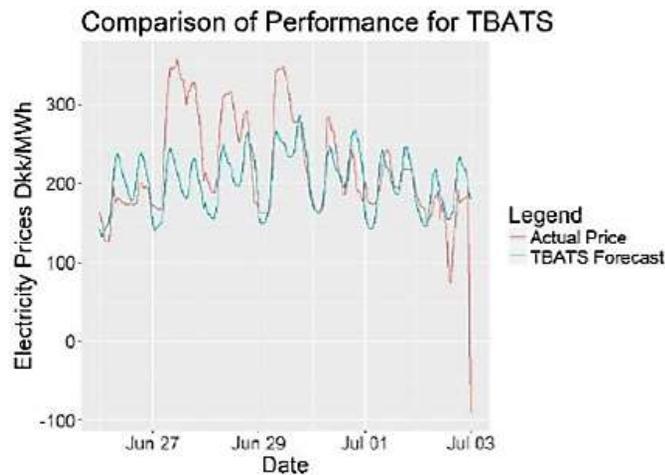


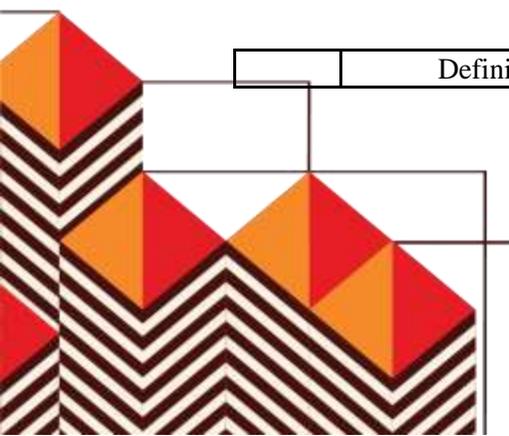
Figura 2. Pronóstico de precio de la electricidad con TBATS en última semana de junio. Fuente: [10].

**MULTIVARIATE ADAPTATIVE REGRESSION SPLINE (MARS)**

En la Tabla 3 se describe la definición general, algunas aplicaciones de esta metodología de estimación y sus resultados en función de los errores tenidos en cuenta en cada aplicación.

Tabla 3. Definición y aplicaciones MARS.

	Definición	Aplicaciones y errores
--	------------	------------------------



MARS	Es un método de análisis de regresión propuesto por Friedman, que es un método de regresión no paramétrico [11]. Fue creado para su uso en funciones lineales o cúbicas. Normalmente, el método es una herramienta estadística flexible y rápida gestionada a través de un método integrado de modelado lineal y no lineal [12].	<ol style="list-style-type: none"> <li>1. Pronóstico de la producción de energía diaria de un sistema fotovoltaico conectado a la red basado en MARS [13]. MARS MAPE (%): 41.3</li> <li>2. Pronóstico del precio de la energía de Ontario por hora mediante MARS [14]. Escenario 1 MAPE (%): 13.1 Escenario 2 MAPE (%): 11.8</li> <li>3. Predicción de la demanda de energía de transporte: splines de regresión adaptativa multivariable [15]. (GR<sup>2</sup>)<sup>4</sup>: Modelo 1: 0.839; Modelo 2: 0.978 Modelo 3: 0.979 Modelo 4: 0.978 Modelo 5: 0.972</li> </ol>
------	--	---

### Error de predicción:

La metodología de estimación utilizada en [15] demuestra que el modelo MARS es efectivo al predecir la demanda de energía en el sector transporte de Turquía. En este estudio se emplearon 5 modelos diferentes de pronósticos con el precio del petróleo como factor común para un periodo de tiempo entre 1975-2019. De todos estos, el modelo 3 presenta mejor comportamiento de pronóstico, resultando con el mayor valor de capacidad de generalización (GR<sup>2</sup>).

<sup>4</sup> Error generalizado de validación cruzada normalizado (GR<sup>2</sup>): brinda información sobre qué tan bien el modelo construido para el conjunto de entrenamiento puede predecir el conjunto de prueba. Fuente: [15].

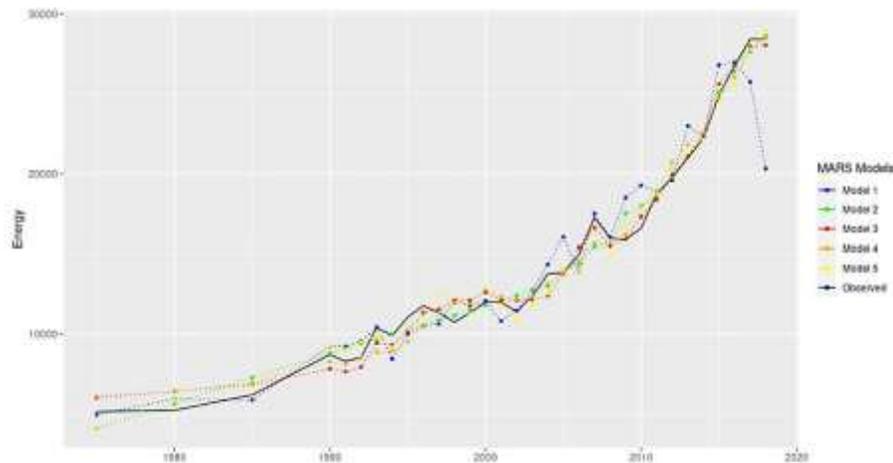


Figura 3. Pronóstico de demanda energética en el sector transporte de Turquía con modelo MARS. Fuente: [15].

### ARTIFICIAL NEURAL NETWORK (ANN)

En la Tabla 4 se describen la definición general, algunas aplicaciones de esta metodología de estimación y sus resultados en función de los errores tenidos en cuenta en cada aplicación.

Tabla 4. Definición y aplicaciones ANN.

	Definición	Aplicaciones y errores
ANN	Las redes neuronales artificiales son herramientas de modelado basadas en datos eficientes ampliamente utilizadas para el modelado dinámico de sistemas no lineales [16], también son empleadas para previsión de demanda de energía. Esta red está formada por tres capas: capa de entrada que toma los datos de la red, capa (s) oculta (s) que reciben la información sin procesar de la capa de entrada y la procesan, y por último la capa de salida que también procesará la información de la capa oculta [17].	<ol style="list-style-type: none"> <li>1. Pronóstico de la demanda de carga de vehículos eléctricos utilizando modelos de series de tiempo [18]. ANN RSME &gt; 9%</li> <li>2. Estudio de pronóstico de carga eléctrica utilizando el método de red neuronal artificial para minimizar apagones [19]. Error promedio (%): Algoritmo 1: 0.39; Algoritmo 2: 0.42; Algoritmo 3: 0.32</li> <li>3. Pronóstico de carga eléctrica basado en ANN aplicado a datos en tiempo real [20]. AFER<sup>5</sup> (%): Tendencia lineal basada en ANN: 15.07; Tendencia parabólica basada en ANN: 16.68; Tendencia exponencial basada en ANN: 26.79</li> </ol>

<sup>5</sup> AFER: Error de pronóstico promedio (Average Forecast Error). Fuente: [20].

### Error de predicción:

En el estudio realizado en [18], de todos los modelos implementados para el pronóstico de demanda eléctrica, la estimación a través de ANN presentó un buen comportamiento de previsión y la inclusión de variables exógenas (independientemente de los datos históricos) condujo a una mayor precisión del pronóstico a nivel país y de ciudad [18].

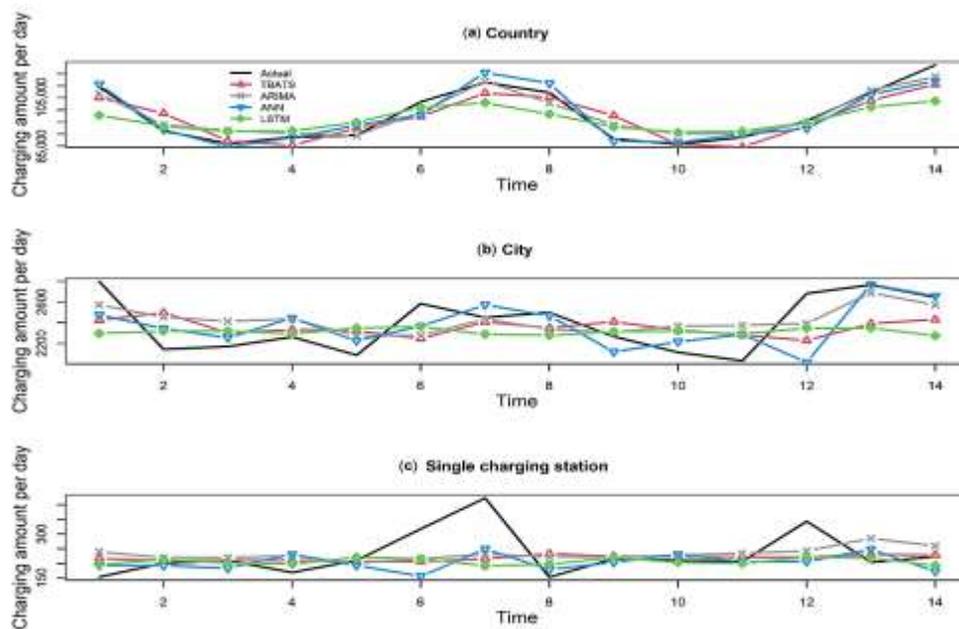


Figura 4. Pronóstico de demanda eléctrica en un día para vehículos eléctricos en escalas (a) país, (b) ciudad, (c) única estación de carga. Fuente: [18].

### RECURRENT NEURAL NETWORK (RNN)

En la Tabla 5 se describe la definición general, algunas aplicaciones de esta metodología de estimación y sus resultados en función de los errores tenidos en cuenta en cada aplicación.

Tabla 5. Definición y aplicaciones RNN.

	Definición	Aplicaciones y errores
RNN	La red neuronal recurrente (RNN) Es un modelo basado en secuencias	1. Pronóstico de carga a corto plazo para estaciones de carga de vehículos eléctricos basado en enfoques de

diseñado para procesar las dependencias de dichas secuencias [16]. Este tipo de redes neuronales tienen la habilidad de aprender sobre datos con series temporales. Estas redes tienen una capa entrada, capas ocultas y capa de salida [17]. Los estados ocultos permiten almacenar información sobre el pasado.	aprendizaje profundo [21].	NMAE (%)
	Modelo 1:	1.60
	Modelo 2:	1.47
	Modelo 3:	2.93
	2. Aprendizaje por conjuntos para la previsión de la carga de las estaciones de recarga de vehículos eléctricos [22].	MAPE (%): 2.44.
	3. Pronóstico de carga eléctrica a corto plazo utilizando Red Neuronal Recurrente [23].	MAPE (%):
	Modelo 1:	1,47
	Modelo 2:	1.60

### Error de predicción:

El comportamiento del pronóstico realizado con 6 modelos para la previsión de carga en estaciones de recarga para vehículos eléctricos en [22] muestra una estimación de 7 días donde la metodología basada en RNN posee el segundo error medio absoluto más bajo de los modelos implementados, sin embargo, como se puede evidenciar en la Figura 5 la mayoría de los modelos empleados presentan buen seguimiento de los datos reales.

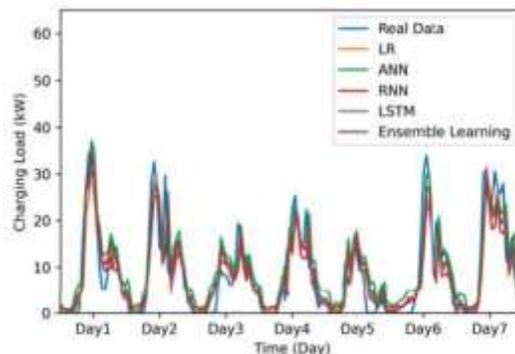


Figura 5. Previsión de carga en estaciones de recarga para una semana con diferentes modelos.

Fuente: [22].

### LONG SHORT-TERM MEMORY (LSTM).



En la Tabla 6 se describe la definición general, algunas aplicaciones de esta metodología de estimación y sus resultados en función de los errores tenidos en cuenta en cada aplicación.

Tabla 6. Definición y aplicaciones LSTM.

	Definición	Aplicaciones y errores
LSTM	<p>Creada por Sepp Hochreiter y Juergen Schmidhuber en 1997, es un versión mejorada de las redes neuronales recurrentes [24].</p> <p>Las unidades de memoria a largo-corto plazo LSTM permiten el constante flujo de errores en la red al implementar una cadena de errores constantes en una unidad compleja nombrada celdas de memoria, donde se guarda información del pasado. Tres unidades multiplicativas (compuerta de entrada, una compuerta de salida y una compuerta de olvido) son las encargadas de ayudar que la información sea almacenada, escrita o leída de las celdas y, en conjunto con una compuerta de actualización, se actualice el estado de la celda [25].</p>	<ol style="list-style-type: none"> <li>1. Predicción del precio de la energía en el mercado rumano utilizando redes de memoria a corto plazo [26]. Error promedio (%): Modelo 1 semana: 9.3 Modelo 1 mes: 22.1</li> <li>2. Aprendizaje por conjuntos para la previsión de la carga de las estaciones de recarga de vehículos eléctricos [18]. RMSE LSTM &gt; 15%</li> <li>3. Red de memoria a largo plazo y regresión de vectores de soporte para el pronóstico de carga eléctrica [27]. MAPE (%): Caso 1: 92.24 Caso 2: 73.79 Caso 3: 90.78</li> </ol>

### Error de predicción:

En [27] para el pronóstico de carga eléctrica se analizan tres casos diferentes, donde en los dos primeros casos se combina red LSTM con otra técnica de aprendizaje profundo para el pronóstico y para el tercer caso se utiliza solo red LSTM. Los resultados de esta investigación ilustrados en la **¡Error! No se encuentra el origen de la referencia.** revelan que la red LSTM presenta la segunda mejor estimación del pronóstico.



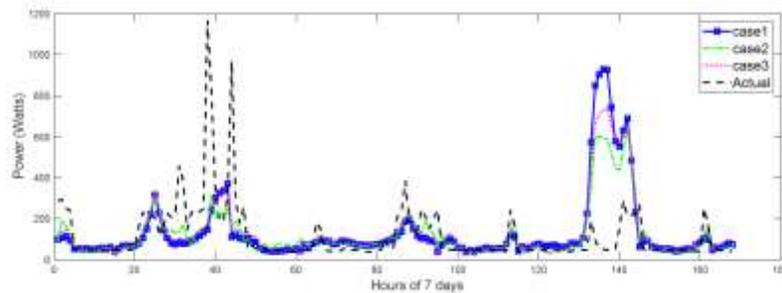


Figura 8. Curvas de pronóstico de carga durante 7 días con LSTM. Fuente: [27].

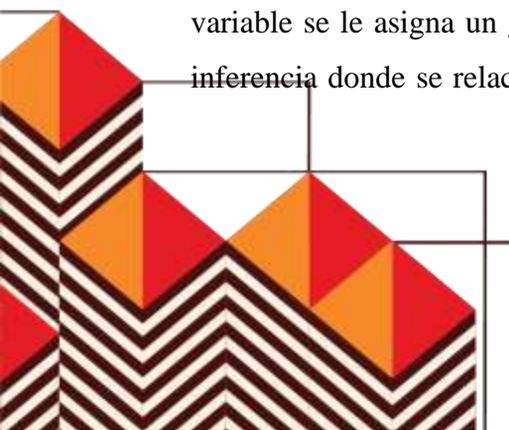
## LÓGICA DIFUSA

En la Tabla 7 se describe la definición general, algunas aplicaciones de esta metodología de estimación y sus resultados en función de los errores tenidos en cuenta

Tabla 7. Definición y aplicaciones Lógica Difusa.

	Definición	Aplicaciones y errores
Lógica Difusa	<p>Se ha considerado que el concepto de lógica difusa dio su primera aparición en 1965 en la universidad de California en Berkeley, introducido por Lofti A. Zadeh [28].</p> <p>Las lógicas difusas propenden crear aproximaciones matemática en la resolución de ciertos tipos de problemas, arrojando resultados exactos a partir de datos imprecisos, por lo cual son útiles en aplicaciones computacionales o electrónicas [29]. Esta permite la implementación de valores intermedios para poder definir valoraciones entre sí/no, verdadero/falso, negro/blanco, pequeño/grande, entre otros [30].</p>	<ol style="list-style-type: none"> <li>Enfoque difuso para la previsión de la carga a corto plazo [31]. Error promedio (%): <math>\pm 3</math></li> <li>Pronóstico de la demanda eléctrica a corto plazo con lógica difusa [32]. MAPE (%): Lógica Difusa: 1.51 - Método Tradicional: 2</li> <li>Previsión de la carga eléctrica mediante lógica difusa [33]. Error respecto a datos reales (MW): Lógica difusa: 27.8 - Excel Forecasting: 38.64</li> </ol>

Muchas metodologías de estimación han sido desarrolladas con esta lógica para control y pronóstico de variables, donde su estructura general se compone de un bloque difusor donde a cada variable se le asigna un grado de pertenencia a cada conjunto difuso considerado, un bloque de inferencia donde se relacionan los conjuntos difusos de entrada y salida con una serie de reglas



asociadas al sistema, y un bloque desdifusor en el cual a partir del conjunto difuso obtenido en el bloque de inferencia y mediante métodos matemáticos de desdifusión como el centroide (es uno de los más utilizados), se obtiene el resultado.

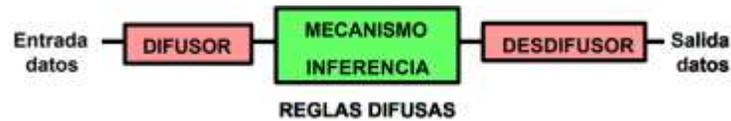


Figura 9. Esquema general de un sistema basado en lógica difusa. Fuente: [34]

### Error de predicción:

Para el modelo empleado en [32] se utiliza lógica difusa para lograr un error menor en el pronóstico de la demanda eléctrica diaria en comparación con el método tradicional utilizado en Perú. En la **¡Error! No se encuentra el origen de la referencia.** se puede apreciar que el modelo basado en lógica difusa sigue de forma más precisa los datos reales en comparación con el modelo de previsión tradicional, resultando un error menor para el pronóstico basado en lógica difusa.

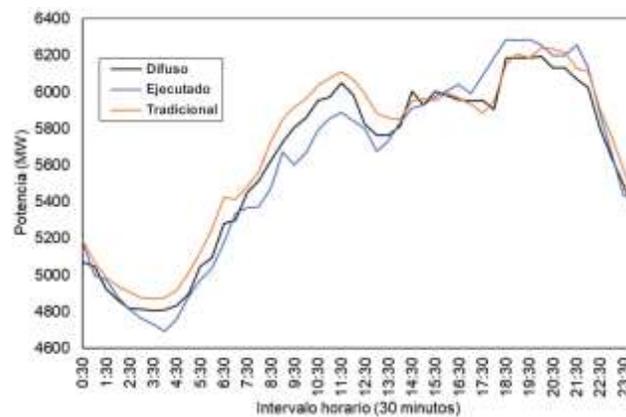
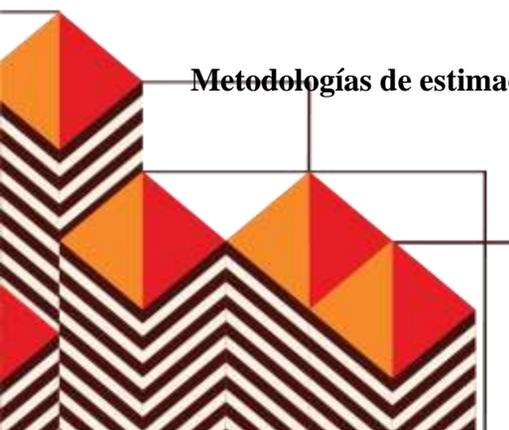


Figura 10. Estimación de demanda eléctrica utilizando lógica difusa. Fuente: [32].

## 4- DISCUSIÓN

### Metodologías de estimación:



DESAMPARADOS No.201, MUELLE "JUAN MANUEL DÍAZ",  
HABANA VIEJA, LA HABANA, CUBA.  
Telef: (53) 7861 0920  
ipin@enet.cu

La mayoría de las metodologías de estimación empleadas para la predicción de consumo eléctrico y demanda energética recopiladas en esta investigación han sido implementadas para pronósticos a nivel residencial, comercial e industrial, con histórico de datos de asociados a la variable analizada como información de entrada, demostrando buenas capacidades de previsión que pueden dar a conocer el posible comportamiento que tendrán los sistemas a futuro.

### **Impactos en la matriz energética:**

La baja penetración de la electromovilidad en los modos férreo y fluvial, tanto para el transporte de carga como de pasajeros es consecuencia de las bajas tasas de reemplazo de las tecnologías empleadas en la actualidad tanto en la red ferroviaria nacional como en la flota de embarcaciones fluviales, en parte por la ausencia de estudios disponibles que permitan determinar la viabilidad técnico-económica.

Un estudio de predicción de consumo eléctrico es útil como información de entrada para identificar restricciones técnicas como son la autonomía de viaje limitada y los largos tiempos de carga, permitiendo la planeación estaciones de carga en donde se busque la estabilidad del sistema energético a través de tecnologías Grid Edge, como generación distribuida, almacenamiento y microrredes.

## **5- CONCLUSIONES**

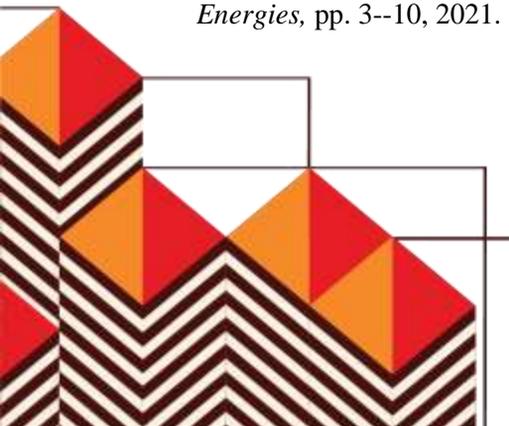
1. Este estudio contribuye al conocimiento de diferentes perspectivas que se pueden tener en cuenta al momento de abordar una temática de gran importancia como lo es la estimación de consumo eléctrico.
2. Para la determinación de una metodología de estimación de consumo eléctrico en embarcaciones con sistemas de electromovilidad es mandatorio el levantamiento de un registro de datos en embarcaciones que posean estas tecnologías.



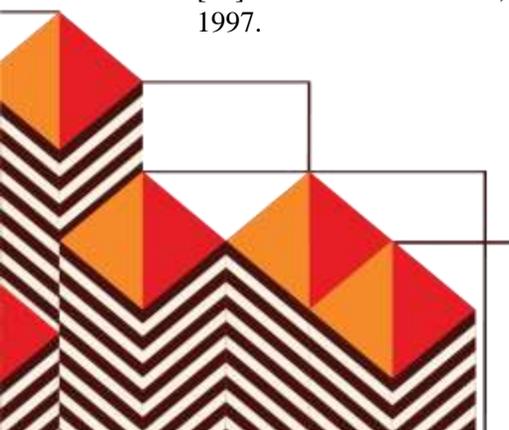
3. La predicción de consumo eléctrico puede ser abordada con diferentes metodologías de previsión y a la vez con diversos datos de entrada.
4. La efectividad de las metodologías descritas en esta investigación está sujeta al histórico de datos recopilado, entre más información posea este para entrenar el modelo predictivo, mayor será la precisión en la estimación de la variable analizada.
5. Se recomienda para trabajos futuros investigar con más profundidad la existencia de otras metodologías de estimación implementadas para previsión de consumo eléctrico.

## 6- REFERENCIAS BIBLIOGRÁFICAS

- [1] T. a. o. Hong, «Energy forecasting: Past, present, and future,» *Foresight: The International Journal of Applied Forecasting*, n° 32, pp. 43--48, 2014.
- [2] G. E. a. J. G. M. a. R. G. C. a. L. G. M. Box, *Time series analysis: forecasting and control*, John Wiley & Sons, 2015.
- [3] K. a. K. A. B. Goswami, «Electricity Demand Prediction using Data Driven Forecasting Scheme: ARIMA and SARIMA for Real-Time Load Data of Assam,» de *2020 International Conference on Computational Performance Evaluation (ComPE)*, 2020, pp. 570--571.
- [4] R. Jamil, «Hydroelectricity consumption forecast for Pakistan using ARIMA modeling and supply-demand analysis for the year 2030,» *Renewable Energy*, vol. 154, pp. 1--10, 2020.
- [5] A. a. F. U. a. F. A. a. C. R. a. P. F. Gellert, «Forecasting Electricity Consumption and Production in Smart Homes through Statistical Methods,» *Sustainable Cities and Society*, p. 103426, 2021.
- [6] Y. a. W. J. a. Z. G. a. D. Y. Wang, «Application of residual modification approach in seasonal ARIMA for electricity demand forecasting: A case study of China,» *Energy Policy*, vol. 48, pp. 284--294, 2012.
- [7] A. M. a. H. R. J. a. S. R. D. De Livera, «Forecasting time series with complex seasonal patterns using exponential smoothing,» *Journal of the American statistical association*, pp. 93--165, 2011.
- [8] M. H. a. H. E. E. a. M. N. H. a. o. Jifri, «Time series performance for electricity load demand in Johor,» de *TENCON 2017-2017 IEEE Region 10 Conference*, IEEE, 2017, pp. 998--1003.
- [9] Y. a. K. S. Kim, «Forecasting Charging Demand of Electric Vehicles Using Time-Series Models,» *Energies*, pp. 3--10, 2021.



- [10] O. A. a. X. G. Karabiber, «Electricity price forecasting in the Danish day-ahead market using the TBATS, ANN and ARIMA methods,» *Energies*, vol. 12, n° 5, pp. 1--2019, 2019.
- [11] S. a. J. Y. a. T. C. a. X. Z. a. X. S. Liuping, «Objective Evaluation Method for Speech Articulation Using Multivariate Adaptive Regression Splines,» *Journal of Data Acquisition \& Processing*, vol. 23, pp. 100--103, 2008.
- [12] M. A. a. D. H. a. { . M. Y. a. E. E. Sahraei, «Prediction of transportation energy demand: multivariate adaptive regression splines,» *Energy*, vol. 224, pp. 1--3, 2021.
- [13] Y. a. H. Y. a. S. Y. a. S. L. Li, «Forecasting the daily power output of a grid-connected photovoltaic system based on multivariate adaptive regression splines,» *Applied Energy*, vol. 180, pp. 392--401, 2016.
- [14] H. a. B. K. a. C. C. A. Zareipour, «Forecasting the hourly Ontario energy price by multivariate adaptive regression splines,» de *2006 IEEE Power Engineering Society General Meeting*, IEEE, 2006, pp. 1--7.
- [15] M. A. a. D. H. a. { . M. Y. a. E. E. Sahraei, «Prediction of transportation energy demand: multivariate adaptive regression splines,» *Energy*, vol. 224, pp. 1--3, 2021.
- [16] S. Shokry y A. Espuña, «The Ordinary Kriging in Multivariate Dynamic Modelling and Multistep-Ahead Prediction,» de *Computer Aided Chemical Engineering*, vol. 43, Elsevier, 2018, pp. 265-270.
- [17] M. Imran y S. A. Alsuhaibani, «A Neuro-Fuzzy Inference Model for Diabetic Retinopathy Classification,» de *Intelligent Data Analysis for Biomedical Applications*, Elsevier, 2019, pp. 147-172.
- [18] K. Yunsun y K. Sahm, «Forecasting Charging Demand of Electric Vehicles Using Time-Series Models,» *Energies*, vol. 14, n° 5, 2021.
- [19] H. a. S. M. D. Mubarak, «Electrical load forecasting study using artificial neural network method for minimizing blackout,» de *2018 5th International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE)*, IEEE, 2018, pp. 256--259.
- [20] S. a. S. A. K. a. o. Khatoon, «ANN based electric load forecasting applied to real time data,» de *2015 Annual IEEE India Conference (INDICON)*, IEEE, 2015, pp. 1--5.
- [21] Z. Juncheng, Y. Zhile, G. Yuanjun, Z. Jiankang y Y. Huikun, «Short-Term Load Forecasting for Electric Vehicle Charging Stations Based on Deep Learning Approaches,» *Applied Sciences*, vol. 9, 2019.
- [22] X. a. W. D. a. B. B. Huang, «Ensemble Learning for Charging Load Forecasting of Electric Vehicle Charging Stations,» de *2020 IEEE Electric Power and Energy Conference (EPEC)*, IEEE, 2020, pp. 1--5.
- [23] M. A. a. H. S. P. a. P. L. M. Yahya, «Short-Term Electric Load Forecasting Using Recurrent Neural Network (Study Case of Load Forecasting in Central Java and Special Region of Yogyakarta),» de *2018 4th International Conference on Science and Technology (ICST)*, IEEE, 2018, pp. 1--6.
- [24] S. a. S. J. Hochreiter, «Long short-term memory,» *Neural computation*, vol. 9, n° 8, pp. 1735--1780, 1997.



- [25] Y. a. T. K. F. He, «Universities power energy management: A novel hybrid model based on iCEEMDAN and Bayesian optimized LSTM,» *Energy Reports*, vol. 7, pp. 6477--6479, 2021.
- [26] A. & T. R. Ioaneş, «Energy Price Prediction on the Romanian Market using Long Short-Term Memory Networks,» de *2019 54th International Universities Power Engineering Conference (UPEC)*, IEEE, 2019, pp. 1--5.
- [27] M. Imani, «Long short-term memory network and support vector regression for electrical load forecasting,» de *2019 International Conference on Power Generation Systems and Renewable Energy Technologies (PGSRET)*, IEEE, 2019, pp. 1--6.
- [28] L. A. Zadeh, «Fuzzy logic,» *Computer*, vol. 21, n° 4, pp. 83--93, 1988.
- [29] G. MORALES LUNA, «Introducción a la lógica difusa,» *Centro de Investigación y Estudios Avanzados. México*, 2002.
- [30] C. a. D. V. E. L. a. o. Eduardo, «Introducción al razonamiento aproximado: lógica difusa,» *Revista Americana de Medicina Respiratoria*, vol. 6, n° 3, pp. 128--130, 2006.
- [31] S. C. a. D. K. a. R. C. C. A. a. K. N. Pandian, «Fuzzy approach for short term load forecasting,» *Electric power systems research*, vol. 76, n° 6-7, pp. 541--548, 2006.
- [32] J. a. N. J. a. o. Blancas, «Pronóstico de la demanda eléctrica a corto plazo con lógica difusa,» *ENERLAC. Revista de energía de Latinoamérica y el Caribe*, vol. 2, n° 1, pp. 8--27, 2018.
- [33] P. a. M. G. a. B. S. a. M. G. Mukhopadhyay, «Electricity load forecasting using fuzzy logic,» de *2017 7th International Conference on Power Systems (ICPS)*, IEEE, 2017, pp. 812--819.
- [34] R. P. Puello, «www.tdx.cat,» [En línea]. Available: <https://www.tdx.cat/bitstream/handle/10803/6887/04Rpp04de11.pdf>.
- [35] M. H. a. H. E. E. a. M. N. H. Jifri, «Forecasting performance of time series and regression in modeling electricity load demand,» de *2017 7th IEEE International Conference on System Engineering and Technology (ICSET)*, IEEE, 2017, pp. 12--16.
- [36] C. a. K. J. a. L. A. Dittmer, «Power demand forecasting for demand-driven energy production with biogas plants,» *Renewable Energy*, vol. 163, pp. 1871--1877, 2021.
- [37] T. S. a. A. R. S. a. L. J. Hui, «Comparison between multiple regression and multivariate adaptive regression splines for predicting CO 2 emissions in ASEAN countries,» de *2013 8th International Conference on Information Technology in Asia (CITA)*, IEEE, 2013, pp. 1--5.
- [38] D. H. a. C. W. a. L. S. a. L. S. Li, «Estimation of hourly global solar radiation using Multivariate Adaptive Regression Spline (MARS)--A case study of Hong Kong,» *Energy*, vol. 186, pp. 1--14, 2019.
- [39] P. a. O. T. a. E. S. a. M. R. a. E. R. Bajpai, «BATSense: Anomalous Security Event Detection using TBATS Machine Learning,» de *2019 International Conference on Cyber Security and Protection of Digital Services (Cyber Security)*, IEEE, 2019, pp. 1--8.



- [40] G. Jinquan, H. Hongwen y S. Chao, «ARIMA-Based Road Gradient and Vehicle Velocity Prediction for Hybrid Electric Vehicle Energy Management,» *IEEE Transactions on Vehicular Technology*, vol. 68, n° 6, pp. 5309-5320, Junio 2019.
- [41] I. Mona, J. Samir, W. Geneviève y H. Daniel, «Nonlinear autoregressive neural network in an energy management strategy for battery/ultracapacitor hybrid electrical vehicles,» *Electric Power Systems Research*, vol. 136, pp. 262-269, 2016.
- [42] X. a. F. F. a. L. J. Zhang, «Weather-classification-MARS-based photovoltaic power forecasting for energy imbalance market,» *IEEE Transactions on Industrial Electronics*, vol. 66, n° 11, pp. 8692--8702, 2019.
- [43] Y. a. K. S. Kim, «Forecasting Charging Demand of Electric Vehicles Using Time-Series Models,» *Energies*, vol. 14, n° 5, pp. 0--16, 2021.
- [44] H.-g. a. K. Y. a. K. S. Son, «Time Series Clustering of Electricity Demand for Industrial Areas on Smart Grid,» *Energies*, vol. 13, n° 9, pp. 2--14, 2020.
- [45] C. a. D. V. E. L. a. o. Eduardo, «Introducción al razonamiento aproximado: lógica difusa,» *Revista Americana de Medicina Respiratoria*, vol. 6, n° 3, pp. 128 -- 130, 2006.
- [46] S. Acharya, «towardsdatascience.com,» 13 05 2021. [En línea]. Available: <https://towardsdatascience.com/what-are-rmse-and-mae-e405ce230383>.

