



# Revisión sistemática de literatura sobre modelos de pronósticos de consumo de energía eléctrica \*

Agustín Mazzeo \*\*  
Lina Sepúlveda-Cano \*\*\*  
Luisa F. Villa \*\*\*\*  
Ricardo Gallego-Burgos \*\*\*\*\*

Recibido: 2018/10/22 • Aceptado: 2019/07/09  
<https://doi.org/10.22395/riium.v19n36a6>

## Resumen

El creciente consumo de energía eléctrica, los cambios climáticos y el desarrollo de nuevas tecnologías exigen mejoras para la gestión eficiente de la energía. El adecuado pronóstico del consumo de energía es relevante para el desarrollo sostenible de cualquier país. En este artículo se propone una revisión sistemática de literatura seleccionada a partir de cadenas de búsqueda formada por las palabras *forecasting*, *energy* y *consumption* aplicadas en las bases de datos científicas. Se comparan principalmente los modelos/técnicas utilizadas, las variables consideradas y las métricas de error usadas con el fin de obtener conocimiento de cada una de las propuestas, relevar sus características y así poder evidenciar el vacío en la literatura que podría determinar la semilla para un nuevo trabajo de investigación. Como conclusiones se observan el uso continuo de redes neuronales artificiales para el pronóstico de consumo, la importancia de determinar las variables de entrada y la medición del error para evaluar la precisión de los modelos. Finalmente, como nueva línea de investigación se propone desarrollar un modelo para el pronóstico de corto plazo de CEE para un país latinoamericano en vías de desarrollo, a partir de la comparación y evaluación de diferentes técnicas/modelos, variables y herramientas ya existentes.

**Palabras clave:** previsión; consumo de energía; corto plazo; largo plazo; redes neuronales.

\* Este artículo de revisión es producto de la investigación titulada *Diseño de un modelo de pronóstico para la mejora de las ofertas comerciales en el Mercado Eléctrico Mayorista de México: Caso MVM*.

\*\* Ingeniero en informática, Estudiante de la Maestría en Ingeniería de *Software* de la Universidad de Medellín. Consultor líder de analítica en MVM Ingeniería de *Software* SAS Medellín, Colombia. Correo electrónico: [agustin.mazzeo@mvm.com.co](mailto:agustin.mazzeo@mvm.com.co)

\*\*\* Doctora en Ingeniería – Línea automática. Ingeniera Electrónica. Profesora asistente, Universidad de Medellín, Medellín, Colombia. Correo electrónico: [lmsepulveda@udem.edu.co](mailto:lmsepulveda@udem.edu.co). Orcid: <https://orcid.org/0000-0003-1749-816X>

\*\*\*\* Doctora en Procesos y Sistemas. Ingeniera de Sistemas. Profesora asistente, Universidad de Medellín, Medellín, Colombia. Correo electrónico: [lvilla@udem.edu.co](mailto:lvilla@udem.edu.co). Orcid: <http://orcid.org/0000-0003-2014-7643>

\*\*\*\*\* Magister en Gestión Tecnológica, Ingeniero de Sistemas. Director de innovación en MVM Ingeniería de *Software* SAS. Medellín, Colombia. Correo electrónico: [ricardo.gallego@mvm.com.co](mailto:ricardo.gallego@mvm.com.co)

## Systematic review of literature on electrical energy consumption forecast models

### **Abstract**

The growing consumption of electrical energy, climate change and the development of new technologies demand improvements for efficient energy management. An adequate forecast of the energy consumption is relevant for the sustainable development of any country. This article proposes a systematic review of selected literature based on search chains formed by the terms forecasting, energy and consumption applied to the scientific databases. In the article are compared mostly the models/techniques used, the considered variables and the error metrics used for obtaining knowledge on each one of the proposals, relieve its features and thus highlight the void in the literature that might be determinant for new research work. As conclusions are made evident the continuous use of neural networks for forecasting the energy consumption, the importance of determining the input variables and the error measuring for evaluating the precision of the models. Finally, the development of a model for the CEE short term forecast of a Latin-American developing country based on the comparison and evaluation of different techniques/models, variables and already existing tools is proposed as a new line of research.

**Keywords:** forecast; energy consumption; short term; long term; neural networks.

## Revisão sistemática de literatura sobre modelos de previsão de consumo de energia elétrica

### **Resumo**

O crescente consumo de energia elétrica, as mudanças climáticas e o desenvolvimento de novas tecnologias exigem melhoras para a gestão eficiente da energia. A adequada previsão do consumo de energia é relevante para desenvolver sustentável de qualquer país. Neste artigo, é proposta uma revisão sistemática de literatura selecionada a partir de redes de busca formada pelas palavras “*forecasting*”, “*energy*” e “*consumption*” aplicadas nas bases de dados científicas. São comparados, principalmente, os modelos ou técnicas utilizados, as variáveis consideradas e as medidas de erro usadas a fim de obter conhecimento de cada uma das propostas, destacar suas características e, assim, poder evidenciar a lacuna na literatura que poderia determinar a semente para um novo trabalho de pesquisa. Como conclusões, são observados o uso contínuo de redes neurais artificiais para prognosticar o consumo, a importância de determinar variáveis de entrada e a medição do erro para avaliar a exatidão dos modelos. Finalmente, como nova linha de pesquisa, propõe-se desenvolver um modelo para prever, em curto prazo, de CEE para um país latino-americano em via de desenvolvimento, a partir da comparação e da avaliação de diferentes técnicas e modelos, variáveis e ferramentas já existentes.

**Palavras-chave:** previsão; consumo de energia; curto prazo; longo prazo; redes neurais.

## INTRODUCCIÓN

El constante incremento del consumo de energía eléctrica (CEE) [1-2], estrechamente ligado al desarrollo socioeconómico [3-4], se ha convertido en uno de los temas que más ocupa la atención de políticos y científicos, tanto para determinar políticas de energía [3-5] como para considerar la disminución de costos en todos los puntos de su proceso de producción (generación, distribución y consumo, con énfasis en este último) [6-7] y preservar el medio ambiente [8-9]. La marcada tendencia a la desregulación del mercado de la energía eléctrica [10-11], los cambios climáticos [12-13], la expansión del uso de las energías renovables [14] y la escasez de combustibles fósiles hacen más complejo el escenario; por lo tanto, contar con pronósticos de CEE que den cuenta acabadamente de esta complejidad se vuelve un desafío.

Las investigaciones en pronóstico de CEE abarcan un conjunto variado de diferentes aristas del problema, por esta razón se encuentran, tanto trabajos referidos a pronósticos de consumo a largo plazo [1-5], que parten de considerar la correspondencia entre factores socioeconómicos y valores de consumo, como de mediano [4-8] y corto plazo [15-16] donde se consideran otras variables como la temperatura y el día de la semana. Resulta recurrente en la mayoría de los estudios revisados, la dificultad que reviste la selección de variables de entrada [10-17], ya sea por determinar cuáles considerar/no considerar o por la cantidad de datos históricos que habría que incluir, haciendo más compleja aún la definición del modelo de pronóstico.

De forma general, en los estudios sobre pronóstico de CEE y de acuerdo con las restricciones identificadas, se seleccionan los modelos más adecuados o se considera la definición de un nuevo modelo. El objetivo en la mayoría de los casos es encontrar aquel modelo del que se obtengan los pronósticos más precisos, al tiempo que pueda atender la variabilidad de las condiciones en las que tiene lugar el consumo [11-17], por ejemplo, adaptarse a los cambios en los patrones de comportamiento de los consumidores, temperatura ambiental, luminosidad, etc. Para ello, en varios estudios se realizan análisis comparativos entre modelos preexistentes y el modelo propuesto a través de técnicas de medición de error, determinándose el porcentaje de mejora que aportan y en qué aspectos de su desempeño resultan particularmente superiores (por ejemplo, costos computacionales y tiempos de entrenamiento) [16].

Como alternativas, y en aras de una mejor solución, varios autores proponen modelos híbridos que resultan de la combinación de otros ya existentes [1-10], logrando así conjugar las ventajas de los métodos implicados y disminuir las desventajas.

Todos estos estudios proporcionan información relevante de los modelos de predicción de CEE en diferentes escalas de tiempo y haciendo uso de diversas técnicas.

De esta forma, para poder compararlos es necesario clasificarlos bajo algún patrón común que los agrupe. Adicionalmente, se deben describir detalladamente cada uno de los elementos que los componen, así se posibilita la identificación de oportunidades de investigación en el área de pronóstico de CEE. En este sentido, este trabajo propone una revisión sistemática de literatura (RSL) para conocer el estado del arte sobre las técnicas o modelos utilizados para pronosticar CEE, sus características y métodos de evaluación de precisión. El resto del artículo se organiza de la siguiente forma: en la sección 1 se muestra la metodología utilizada para llevar a cabo la RSL. Se describen cuáles fueron los criterios de selección de los artículos considerados, los contenidos de los artículos revisados. Las características de los modelos propuestos en cada uno de los artículos contemplados en la revisión son presentadas a través de gráficos y tablas estadísticas en la sección 2. La sección 3 ofrece un análisis comparativo de los mismos a fin de visualizar sus avances y limitaciones. Finalmente, la sección 4 resume y expone las conclusiones del artículo y se plantea una nueva línea de investigación.

## 1. METODOLOGÍA

La metodología que se siguió para la RSL fue originalmente desarrollada para el ámbito de investigación médica y luego ampliada al campo de estudios de gestión y administración [18]. La misma está compuesta por tres etapas: i) planeación de la revisión, ii) desarrollo de la revisión y iii) desarrollo de reportes y diseminación. Para la primera etapa se tienen las siguientes fases: identificación de la necesidad de una RSL, preparación de una propuesta para la revisión y desarrollo de un protocolo de RSL. En la segunda etapa se consideran la identificación de la investigación, selección de los estudios, evaluación de la calidad del estudio, extracción de los datos, monitoreo del progreso y síntesis de la información. Finalmente, en la última se contemplan el reporte, las recomendaciones y el paso de la evidencia a la práctica.

El objetivo de esta metodología es localizar los estudios relevantes relacionados con las preguntas de la investigación a desarrollar, así como evaluar y sintetizar sus respectivas contribuciones e informar de manera clara los resultados y las conclusiones obtenidas a partir de ellos, con el fin de plantear sus campos de aplicación y nuevas investigaciones [19].

Asimismo, esta metodología se adoptó en aras de reducir el riesgo de sesgado en la selección de la bibliografía por preferencias subjetivas, adoptando para ello estrategias de búsqueda, cadenas de búsquedas predefinidas, criterios de exclusión/inclusión y, al mismo tiempo, ampliar el espectro de la búsqueda más allá del horizonte de la propia experiencia.

## 1.1 PLANEACIÓN DE LA REVISIÓN

Las principales investigaciones en esta área son impulsadas por la utilización de distintas técnicas y modelos, la selección de variables de entrada y la cantidad de historia a utilizar, así como por técnicas para medir la precisión de los resultados. Por tal motivo, es necesario comprender todos los aspectos que involucra desarrollar un modelo de pronósticos de CEE, con el fin de entender las evidencias y desafíos actuales en el pronóstico del consumo de energía. Para ello, se pretende responder las siguientes preguntas de investigación:

PI1: ¿Qué técnicas/modelos se utilizan para la predicción/pronóstico de consumo de energía?

PI2: ¿Qué variables de entrada usan estas técnicas/modelos?

PI3: ¿Qué técnicas se utilizan para evaluar la precisión de las técnicas/modelos? ¿Cuál es la más usada?

## 1.2 Desarrollo de la revisión

El primer paso de la RSL fue definir las cadenas de búsqueda usando palabras clave que estuvieran relacionadas con la definición del problema de investigación, con la intención de garantizar los resultados buscados. Para esto se utilizó la combinación de las palabras *Energy*, *Consumption* y *Forecasting* formando la frase *Energy Consumption Forecasting*. A continuación, se determinaron las bases de datos científicas de donde se obtuvieron los artículos a partir de dicha cadena de búsqueda. Inicialmente se buscó con ella con un ámbito que comprendió el título (*title*), el resumen (*abstract*) y las palabras claves (*keywords*) pero debido al gran número de artículos que se obtuvieron, alrededor de 2.900, se decidió restringir el ámbito de búsqueda de la cadena formada solo al título de los artículos. La tabla 1 muestra las cadenas de búsqueda utilizadas según la sintaxis propia de cada base de datos.

Tabla 1. Cadenas de búsqueda utilizadas en cada base de datos científicas

#	Scopus	Science Direct	Web of Science (WOS)	IEEE
1	TITLE-ABS-KEY (“energy consumption forecasting”)	Title, abstract, keywords: “energy consumption forecasting”	TS=(energy AND consumption AND forecasting)	((“Document Title”:energy consumption forecasting) OR “Abstract”:energy consumption forecasting) OR “Author Keywords”:energy consumption forecasting)
2	TITLE (“Energy consumption forecasting”)	TITLE (“energy consumption forecasting”)	TÍTULO=(energy AND consumption AND forecasting)	(“Document Title”: “energy consumption forecasting”)

Fuente: elaboración propia

En total se obtuvieron 218 artículos combinando los resultados de las bases de datos. A partir de estos resultados se realizó el proceso de selección de los artículos evidenciado y descrito en la figura 1. Además, para la eliminación de los artículos se tuvieron en cuenta los criterios de selección definidos en la tabla 2.

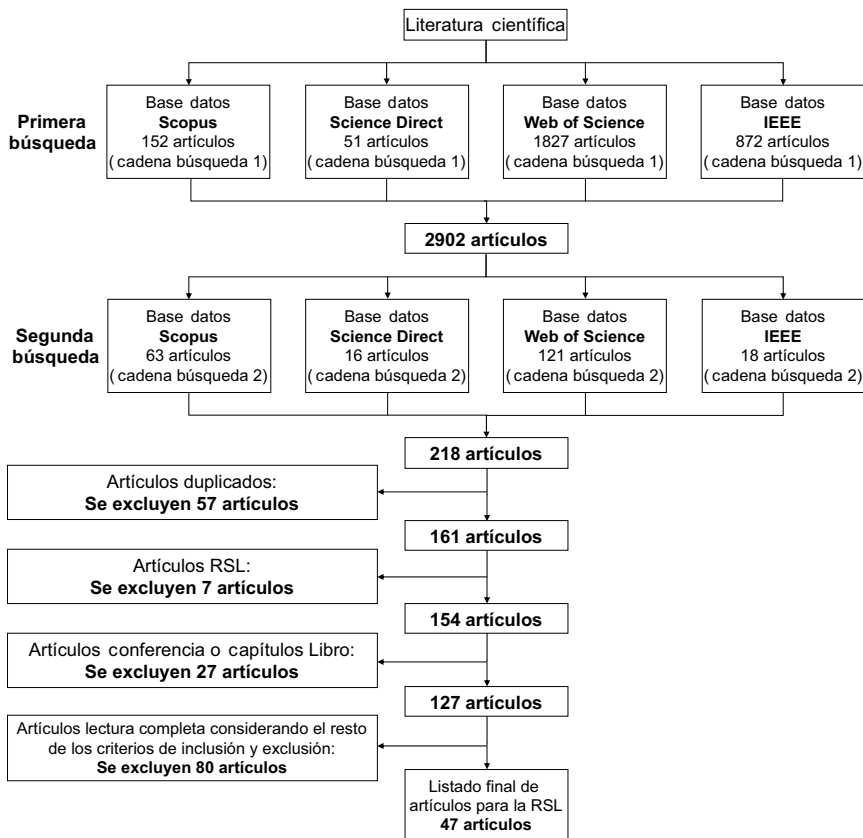


Figura 1. Resumen proceso selección de literatura científica

Fuente: elaboración propia

Tabla 2. Criterios considerados para la selección de artículos

<i>Criterios de inclusión</i>	<i>Criterios de exclusión</i>
Estudios en idioma inglés.	Fuentes secundarias.
Estudios con modelos/técnicas para pronosticar consumos de energía eléctrica medidos en vatios. (kWh, MWh, GWh, TWh).	Estudios duplicados.
	Estudios de dominio distinto al sector de energía.

Fuente: elaboración propia

Como resultado final del proceso de selección se obtuvieron 47 artículos listados en la tabla 3, ordenados de acuerdo con el *ranking* de citación.

Tabla 3. Artículos utilizados para el análisis después de la selección

#-Ref	Artículo	Autores	Año	Citaciones
1-[20]	Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption	Hernández Neto, A. y Sanzovo Fiorelli, F.	2008	196
2-[21]	Time series models (Grey-Markov, Grey Model with rolling mechanism and singular spectrum analysis) to forecast energy consumption in India	Kumar, U. y Jain, V. K.	2010	142
3-[22]	Annual electricity consumption forecasting by neural network in high energy consuming industrial sectors	Azadeh, A., Gha-deri, S. F. y Soh-rabkhani, S.	2008	112
4-[23]	Forecasting energy consumption of multi-family residential buildings using support vector regression: Investigating the impact of temporal and spatial monitoring granularity on performance accuracy	Jain, R. K., Smith, K., Culligan, P. J. y Taylor, J. E.	2014	108
5-[24]	Forecasting of Turkey's net electricity energy consumption on sectoral bases	Hamzacebi, C.	2007	106
6-[25]	Forecasting energy consumption using a grey model improved by incorporating genetic programming	Lee, Y.-S. y Tong, L.-I.	2011	103
7-[26]	Univariate modeling and forecasting of energy consumption: the case of electricity in Lebanon	Saab, S., Badr, E. y Nasr, G.	2001	101
8-[27]	A simulated-based neural network algorithm for forecasting electrical energy consumption in Iran	Azadeh, A., Gha-deri, S. F. y Soh-rabkhani, S.	2008	91
9-[28]	Forecasting building energy consumption using neural networks and hybrid neuro-fuzzy system: A comparative study	Li, K., Su, H. y Chu J.	2011	76
10-[29]	A novel hybrid ensemble learning paradigm for nuclear energy consumption forecasting	Tang, L., Yu L., Wang, S., Li, J. y Wang, S.	2012	69
11-[30]	Integration of genetic algorithm, computer simulation and design of experiments for forecasting electrical energy consumption	Azadeh, A. y Tarverdian, S.	2007	62

<i>#-Ref</i>	<i>Artículo</i>	<i>Autores</i>	<i>Año</i>	<i>Citaciones</i>
12-[31]	A regression model for electric-energy-consumption forecasting in Eastern Saudi Arabia	Al-Garni, A. Z., Zubair, S. M. y Nizami, J. S.	1994	44
13-[2]	Long-term electrical energy consumption forecasting for developing and developed economies based on different optimized models and historical data types	Ardakani, F. J. y Ardehali, M. M.	2014	44
14-[32]	Modeling and forecasting energy consumption for heterogeneous buildings using a physical-statistical approach	Lü, X., Lu, T., Kibert, C. J. y Viljanen, M.	2015	40
15-[33]	Forecasting net energy consumption using artificial neural network	Sözen, A., Akçayol, M. A. y Arcaklioğlu, E.	2006	32
16-[8]	A novel data-characteristic-driven modeling methodology for nuclear energy consumption forecasting	Tang, L., Yu, L. y He, K.	2014	31
17-[34]	Neural networks in forecasting electrical energy consumption: univariate and multivariate approaches	Nasr, G. E., Badr, E. A. y Younes, M. R.	2002	29
18-[35]	Forecasting building energy consumption with hybrid genetic algorithm-hierarchical adaptive network-based fuzzy inference system	Li, K. y Su, H.	2010	25
19-[36]	Time series forecasting for building energy consumption using weighted Support Vector Regression with differential evolution optimization technique	Zhang, F., Deb, C., Lee, S. E., Yang, J. y Shah, K. W.	2016	25
20-[37]	Long term energy consumption forecasting using genetic programming	Karabulut, K., Alkan, A. y Yilmaz, A.	2008	24
21-[38]	Conditional dynamic forecast of electrical energy consumption requirements in Ghana by 2020: A comparison of ARDL and PAM	Adom, P. K. y Bekoe, W.	2012	20
22-[39]	Influence of artificial neural network structure on quality of short-term electric energy consumption forecast	Baczynski, D. y Parol, M.	2004	20
23-[40]	Forecasting energy consumption using ensemble Arima-ANFIS hybrid algorithm	Barak, S. y Sadegh, S. S.	2016	19
24-[41]	Forecasting Monthly Electric Energy Consumption Using Feature Extraction	Meng, M., Niu, D. y Sun, W.	2011	19



#-Ref	Artículo	Autores	Año	Citaciones
25-[42]	Application of Arima for forecasting energy consumption and GHG emission: A case study of an Indian pig iron manufacturing organization	Sen, P., Roy, M. y Pal, P.	2016	16
26-[5]	Multifactor-influenced energy consumption forecasting using enhanced back-propagation neural network	Zeng, Y. R., Zeng, Y., Choi, B. y Wang, L.	2017	14
27-[43]	A novel mode-characteristic-based decomposition ensemble model for nuclear energy consumption forecasting	Tang, L., Wang, S., He, K. y Wang, S.	2015	13
28-[44]	Using connectionist systems for electric energy consumption forecasting in shopping centers	Kamaev, V. A., Shcherbakov, M. V., Panchenko, D. P., Shcherbakova, N. L. y Brebels, A.	2012	13
29-[45]	Fuzzy Wavelet Neural Networks for City Electric Energy Consumption Forecasting	Zhang, P. y Wang, H.	2012	12
30-[10]	Energy Consumption Forecasting Using Semantic-Based Genetic Programming with Local Search Optimizer	Castelli, M., Trujillo, L. y Vanneschi, L.	2015	8
31-[46]	Forecasting Electrical Energy Consumption of Equipment Maintenance Using Neural Network and Particle Swarm Optimization	Jiang, X., Ling, H., Yan, J., Li, B. y Li, Z.	2013	7
32-[47]	Load Forecast Model Switching Scheme for Improved Robustness to Changes in Building Energy Consumption Patterns	Yoo, J. y Hur, K.	2013	7
33-[48]	Electrical energy consumption forecasting based on cointegration and a support vector machine in China	Zhang, X. P. y Rui, G.	2007	5
34-[49]	Energy consumption forecasting based on Elman neural networks with evolutive optimization	Ruiz, L. G. B., Rueda, R., Cuéllar, M. P. y Pegalajar, M. C.	2018	4
35-[50]	Energy consumption forecasting for university sector buildings	Amber, K. P., Aslam, M. W., Mahmood, A., Kousar, A., Younis, M. Y., Akbar, B., Chaudhary, G. Q. y Hussain, S. K.	2017	4
36-[51]	Big Data Mining of Energy Time Series for Behavioral Analytics and Energy Consumption Forecasting	Singh, S. y Yassine, A.	2018	2

<i>#-Ref</i>	<i>Artículo</i>	<i>Autores</i>	<i>Año</i>	<i>Citaciones</i>
37-[16]	Cloud computing and extreme learning machine for a distributed energy consumption forecasting in equipment-manufacturing enterprises	Wang, R. D., Sun, X.S., Yang, X. y Hu, H.	2016	2
38-[52]	Consumption Behavior Analytics-Aided Energy Forecasting and Dispatch	Zhang, Y., Yang, R., Zhang, K., Jiang, H. y Zhang, J. J.	2017	2
39-[53]	Electrical energy consumption forecasting in oil refining industry using support vector machines and particle swarm optimization	Petkovic, M., Rapaić, M. R. y Jakovljević, B.	2009	2
40-[54]	Incorporating the effects of hike in energy prices into energy consumption forecasting: A fuzzy expert system	Majazi Dalfard, V., Nazari Asli, M., Nazari-Shirkouhi, S., Sajadi, S. M. y Asadzadeh, S. M.	2013	2
41-[4]	Monthly electric energy consumption forecasting using multiwindow moving average and hybrid growth models	Meng, M., Shang, W. y Niu, D.	2014	2
42-[55]	An Electrical Energy Consumption Monitoring and Forecasting System	Rojas-Rentería, J. L., Espinoza-Huerta, T. D., Tovar-Pacheco, F. S., González Pérez, J. L. y Lozano-Dorantes, R.	2016	1
43-[56]	Effective electricity energy consumption forecasting using echo state network improved by differential evolution algorithm	Wang, L., Hu, H., Ai, X. Y. y Liu H.	2018	1
44-[57]	Forecasting mid-long term electric energy consumption through bagging Arima and exponential smoothing methods	Meira de Oliveira, E. y Cyrino Oliveira, F. L.	2018	1
45-[58]	Robust ensemble learning framework for day-ahead forecasting of household based energy consumption	Alobaidi, M. H., Chebana, F. y Meguid, M. A.	2018	1
46-[59]	Monthly Energy Consumption Forecasting Based on Windowed Momentum Neural Network	Mishra, S. y Singh, V. K.	2015	0
47-[17]	Universal energy consumption forecasting system based on neural network ensemble	Staroverov, B. A. y Gnatyuk, B. A.	2016	0

Fuente: elaboración propia

## Los acrónimos utilizados en esta RSL (tabla 4):

Tabla 4. Listado de acrónimos utilizados en la RSL

Anfis	Adaptive Neuro-Fuzzy Inference System	HIS	Heavy Industry Share
ANN	Artificial Neural Networks	IMP	Energy Imported
APE	Absolute Percentage Error	IPSO	Improved Particle Swarm Optimization
AR	Auto Regression	LSSVR	Least Squares Support Vector Regression
Arima	Autoregressive Integrated Moving Average	MAE	Mean Absolute Error
Armax	Autoregressive Moving Average with Exogenous Variable	MAED	Model for Analysis of Energy Demand
BP	Back Propagation	MAPE	Mean Absolute Percentage Error
CEE	Consumo de Energía Eléctrica	MaxAPE	Maximal Absolute Percentage Error
CV	Coefficient Variation	MdAPE	Median Absolute Percentage Error
DE	Differential Evolution	ME	Mean Error
Dstat	Directional Statistic	MLP	Multilayer Perceptron
DWT	Discrete Wavelet Transform	MSE	Mean squared error
EEMD	Ensemble Empirical Mode Decomposition	NAR	Nonlinear autoregressive
EIS	Efficient Improvement	NARX	nonlinear autoregressive exogenous
ENN	Elman Neural Network	NRMSE	Normalized Root Mean Square Error
ESN	Echo State Network	POP	Population
EXP	Energy Exported	PSO	Particle Swarm Optimization
FF	Feed Forward	R	Coefficient of Determination
FH	Factor Humedad	RBF	Radial Basis Function
FWNN	Fuzzy Wavelet Neural Network	RM	Regression Model
GA	Genetic Algorithm	RMSE	Root Mean Square Error
GD	Gradient Descent	RS	Radiación Solar
GDP	Gross Domestic Product	SVD	Singular Value Decomposition
GFS	Genetic Fuzzy System	SVM	Support Vector Machine
GM	Grey Model	T	Temperatura
GMARE	Geometric Mean Relative Absolute Error	TI	Total Imports
GP	Genetic Programming	WS	Wind Speed
H	Híbrido		

Fuente: elaboración propia

### 1.3 Reporte y diseminación

Como parte de esta etapa, se realizó una agrupación de los artículos seleccionados por tipo de método/modelo de pronóstico y luego, de acuerdo con el alcance establecido para el pronóstico, en corto y largo plazo. Dentro de cada uno de los grupos, se resumen las características y ventajas más relevantes de los modelos propuestos.

### 1.4 Artificial neural network (ANN)

#### 1.4.1 Corto plazo

En 2004 Bacznski y Parol [39] entrenaron varios modelos de ANN de tipo MLP y concluyeron que el número de peso en la red neuronal debería ser de un orden de magnitud menor que el número de datos de aprendizaje. También observaron que la proporción de número de neuronas en las capas ocultas tiene una influencia considerable en la habilidad de la red neuronal para aprender y generalizar, siendo las mejores las de estructuras balanceadas. Los resultados obtenidos muestran que la estructura ANN tiene una influencia esencial en la calidad de los pronósticos de consumo de energía eléctrica.

Posteriormente, en 2016 Rojas-Rentería *et al.* [55] investigaron un sistema de pronóstico y monitoreo basado en una red neuronal de tipo MLP aplicada en un edificio real. Propusieron un modelo con tres capas. En la capa de entrada utilizaron tres entradas (CEE, hora y día) y en la de salida el CEE con granularidad horaria. Evaluaron el modelo propuesto con distintas configuraciones encontrando que el mejor resultado lo ofrecía la configuración 3-1-1 con un nivel de confianza del 95 % en la predicción.

En 2008 Hernández y Sanzovo [20] compararon su modelo propuesto de ANN de tipo FF con un *software* de simulación que pronostica la demanda de energía para la administración del edificio de la Universidad de Sao Paulo. El modelo fue entrenado con tres *datasets* organizados de diferentes formas: una para todos los días de la semana sin discriminar días laborables de fines de semana, otra para los días laborables y la tercera solo para los fines de semana. La primera presentó mayor error entre la predicción y los datos reales en comparación con las otras dos independientemente de la cantidad de capas ocultas y números de neuronas en cada capa oculta. Entonces incrementaron la complejidad del modelo agregando como variables de entrada la temperatura exterior, la humedad relativa, la radiación solar global y la radiación solar difusa. Concluyeron que se acercaron más a los datos reales cuando discriminaron los *datasets* por fines de semana y días laborables, aunque la inclusión de parámetros climáticos adicionales mejoró levemente los resultados. Finalmente, los resultados mostraron que el modelo de ANN de tipo FF no es el más adecuado para la predicción en este contexto de estudio.

M. Alobaidiam *et al.* [58] en el 2018 presentaron un marco de referencia (*framework*) para predecir el promedio de consumo diario de energía de casas individuales, a partir del uso de un modelo ensamblado que emplea diversidad de información. La propuesta se aplicó en un caso de estudio en Francia. Este modelo supera la generalización de la habilidad y atenuación de varios problemas de predicción inestables de otros modelos, al tiempo que mejora el desempeño de predicción con datos limitados. Construyeron un *framework* con siete submodelos, uno para cada día de la semana, con parámetros determinados a través de estudios de validación cruzada. La validación *Jackknife* fue usada para determinar los valores óptimos de *me* y *mc* del modelo propuesto de cada configuración de ensamble. El proceso fue repetido hasta obtener las estimaciones de ensambles para todas las observaciones disponibles. En la comparación con una red neuronal normal y otra de tipo *Bagging* quedó demostrado que su desempeño era superior.

Ante la situación planteada por Wang *et al.* [16] en 2016, donde los pronósticos en la industria de facturación de equipos requieren un constante entrenamiento debido a que nueva información se genera en forma continua, propusieron una solución utilizando *Hadoop*. Contrastaron tres modelos: el MR-OSELM-WA, el *Functional Networks* y SVM. Los resultados obtenidos les permitieron demostrar que el mejor modelo era MR-OSELM-WA, el cual evidenció que las tecnologías de procesamiento *Big Data* son efectivas para resolver este tipo de problemas dado que acortan los tiempos de entrenamiento, reducen los recursos computacionales y mejoran la precisión del pronóstico.

En el escrito presentado en 2016 por Stareverov y Gnatyuk [17], para resolver los problemas de pronóstico independientemente de la naturaleza de los datos ingresados, plantearon construir un conjunto de ANN con el fin de crear un sistema de pronóstico de carácter universal, capaz de promediar las salidas de las distintas redes neuronales individuales. Los estudios permitieron determinar el conjunto mínimo de factores relevantes, la profundidad y dimensión del vector de entrenamiento de entrada. Finalmente comprobaron que una estructura de tres niveles de conjuntos de redes neuronales tiene un poder predictivo de alto dominio y su uso resulta ser prometedor para tareas relacionadas con información y análisis estadístico.

El estudio de Ruiz *et al.* [49] del 2018, derivó de investigaciones previas donde se utilizaron modelos de pronóstico NAR y NARX. Además, propusieron usar un modelo de red neuronal denominado ENN entrenado con un GA. Puede señalarse que GA resultó ser un factor clave para optimizar las ANN y mejorar los modelos NAR y NARX, mientras que el modelo ENN aportaba mayor exactitud, pero resultaba más complejo por el incremento de componentes de la red neuronal que involucraba. Finalmente, la combinación de ENN + GA, considerando como variables de entrada el consumo de energía eléctrica y la temperatura, resultó ser el mejor modelo.

### 1.4.2 Largo plazo

En el estudio presentado en 2007 por Hamzaçebi [24], este propuso un modelo ANN de tipo MLP basado en valores de observación de un año. Realizó pronósticos de consumo de electricidad en los sectores básicos hasta 2020 comparándolos con los realizados por el MAED utilizado por el gobierno y demostró que eran más exactos. Sin embargo, el objetivo del estudio no pretendía reclamar la constante superioridad del modelo ANN sino indicar a los funcionarios políticos la importancia del uso alternativo de formas de pronóstico.

En el 2008 Azadeh *et al.* [22], presentaron un modelo ANN de tipo MLP para el consumo anual de electricidad en sectores industriales de alto consumo de energía, si bien tradicionalmente las ANN habían sido utilizadas en pronósticos de corto plazo. Probaron varios modelos de ANN variando el número de neuronas en las dos capas ocultas y el método de entrenamiento, concluyendo que a partir de datos reales de consumo en Irán en el período 1979-2003, el modelo con la configuración 5-3-2-1 era el que pronosticaba con mejor precisión.

Ese mismo año, los mismos autores [27] presentaron otro estudio en el que proponían un algoritmo integrado para el pronóstico mensual de consumos de energía eléctrica basado en ANN, una simulación de computadora y el diseño de experimentos usando procedimientos estocásticos. Para ello, construyeron tres modelos: algoritmo integrado basado en ANN, ANN de tipo *times series* y ANN simulado. Buscando demostrar la aplicabilidad y superioridad de estos usaron datos reales de consumo de energía de Irán por 130 meses. Aplicaron la red MLP con tres variables de *input* y pudieron demostrar que la ANN de tipo MLP con configuración 3-2-1 y algoritmo de BP tuvo el mejor resultado con un error relativo igual a 0,012. Además, el modelo ANN era superior con relación al modelo ANN de tipo *Time Series* y el modelo simulado. Sin embargo, argumentaron que el uso de los tres modelos asegura el mejor resultado para datos reales minimizando el sesgo de utilizar un solo enfoque.

En el estudio de Jiang *et al.* [46] de 2013, presentaron un modelo de pronóstico de consumo de energía eléctrica basado en ANN de tipo FF entrenado por PSO. El modelo utilizaba como datos de entrada los consumos eléctricos de energía del equipo, los parámetros del equipo y los parámetros de mantenimiento del equipo. Resultados experimentales les permitieron demostrar la capacidad del modelo para mejorar la precisión de los pronósticos y avanzar en el entendimiento de la relación entre el consumo de energía eléctrica y las variables de entrada.

Mishra y Singh [59] presentaron en 2015 un modelo de red neuronal de tipo FF, que tiene el algoritmo *Windowed Momentum*. La inclusión de este componente permitió a

los operadores superar los problemas por sobrepasar la mínima en iteraciones pequeñas que suelen tener lugar en este tipo de propagación. Igualmente, observaron que si bien, días diferentes de la semana presentaban consumos diferentes de energía, las curvas de consumo para los mismos días dentro del mes en cada año eran casi iguales. Concluyeron que el uso del algoritmo *Windowed Momentum* resultaba ser más eficiente que el *Standard Momentum*.

Nasr *et al.* [34] en 2002, construyeron cuatro modelos de ANN de tipo BP para pronosticar el consumo de energía eléctrica: uno de tipo univariado con tres parámetros de entrada de EEC y otros tres de tipo multivariado con distintas variables de entrada, el primero de estos combinaba las variables EEC y la T, el segundo, empleaba TI y EEC, y el tercero EEC, TI y la T. Los modelos fueron entrenados, probados y evaluados con información real del Líbano entre los periodos 1995-1999. Los resultados mostraron que los modelos multivariados resultaron superiores y dentro de ellos, el que usaba la temperatura y EEC logró el mejor desempeño en el pronóstico.

En 2006 Sözen *et al.* [33], pronosticaron el consumo anual de energía eléctrica de Turquía usando una técnica de red neuronal de tipo BP. Los resultados experimentales les permitieron demostrar que el modelo propuesto lograba predecir dentro de los errores aceptables, utilizando como variables de entrada el año, la población del país, la capacidad instalada de generación y la generación bruta total del país.

En el estudio presentado en 2017 Zeng *et al.* [5], plantearon mejorar el modelo de pronóstico basado en ANN de tipo BP incluyendo el algoritmo inteligente llamado DE. Este modelo fue comparado con otros modelos planteando dos escenarios, el primero utilizaba las variables GDP, POP, IMP y EXP y el segundo, solo la variable CEE. Finalmente confirmaron que el modelo propuesto era el más preciso y de fácil implementación.

Meng *et al.* en 2014 [4] presentaron un modelo *Hybrid Grow*, que incluía un término constante, uno lineal y otro exponencial, combinado con un algoritmo *Multiwindow Moving Average*, que descompone los consumos mensuales en varias series periódicas. Este modelo fue contrastado con otros como Arima y ANN, y concluyeron que el modelo propuesto daba mejores resultados para el pronóstico de consumos de energía anual de China.

En 2018 Wang *et al.* [56], propusieron un nuevo modelo de ANN de tipo ESN que usaba el algoritmo DE, para determinar sus parámetros de configuración, con el fin de pronosticar consumos mensuales y anuales de energía eléctrica para una ciudad de China. Este modelo resultó tener características de fácil implementación y estabilidad, así como superioridad sobre otros modelos en cuanto a la precisión del pronóstico tales como el Arima, BBPN, *basic ESN* y ESN-GA.

## 1.5 Autoregressive Integrated Moving Average (Arima)

### 1.5.1 Corto plazo

Kamaev *et al.* [44] en 2012, propusieron un modelo Arima con cuatro *lags* de entrada de consumos de energía. Construyeron además dos modelos de regresión lineal: uno con cuatro *lags* de consumos de energía eléctrica de entrada al modelo y otro con más entradas adicionales como la temperatura y los parámetros del edificio. Posteriormente implementaron otro modelo de ANN el cual tenía como parámetros de entrada los cuatro *lags* de consumo de energía eléctrica, la temperatura y los parámetros del edificio. Como resultados finales obtuvieron que el modelo Arima era el de ejecución más rápida, pero con menor precisión en el pronóstico de acuerdo con la métrica de error MAPE y el modelo de ANN el de mejor pronóstico.

En 2013 Yoo y Hur [47], emplearon un modelo denominado Armax usando el filtro *Kalman* para estimar los parámetros del modelo pronosticando los consumos de energía eléctrica, con una granularidad horaria en función de su historia y la variable exógena de temperatura. Además, la serie de tiempo fue dividida en dos series, una con los días entre semana y la otra con los días del fin de semana. Finalmente, las simulaciones efectuadas demostraron la efectividad del modelo propuesto.

Zhang *et al.* [52] en 2017, presentaron un marco de referencia (*Framework*) con el objetivo de mejorar el pronóstico de consumos eléctricos fotovoltaicos (PV) para plazos de tiempos muy cortos, usando el comportamiento histórico del consumo de electricidad y la información climática como la temperatura, la *solar global horizontal irradiance*, la humedad relativa, la velocidad del viento y las precipitaciones. La propuesta incluía varios modelos de pronóstico, entre ellos un modelo Arima, un modelo de SVM y varios modelos ANN. Como conclusión dejaron abierta la posibilidad de una investigación futura orientada a incorporar en el *Framework* la selección automática del modelo atenta a establecer el óptimo para cada contexto específico.

### 1.5.2 Largo plazo

En 2001 Saab *et al.* [26], estudiaron diferentes técnicas de modelado univariado para pronosticar los consumos mensuales de energía eléctrica del Líbano usando modelos Arima. Definieron tres modelos: el Arima simple, el AR (1) simple y una configuración nueva combinando el modelo AR (1) con un *highpass*, siendo este último el que obtuvo mejores resultados con respecto a los otros.

En el artículo publicado por Tang *et al.* en 2014 [8], con el fin de mejorar la precisión del pronóstico del consumo de energía nuclear, se presentó una metodología para formular un modelo Arima de pronóstico basado en las características propias



de los datos de muestra. Para esto, los autores construyeron dos modelos adicionales ANN y SVM, con el fin de validar el modelo formulado. Demostraron que el método propuesto mejoraba los desempeños de pronóstico en comparación con los otros que ignoran las características de los datos.

En 2016 Sen *et al.* [42], desarrollaron y evaluaron modelos de pronóstico de consumo de energía mensuales en el sector industrial de producción de hierro y acero de India. Probaron varias configuraciones de modelos Arima y finalmente determinaron que el modelo Arima (1,0,0) x (0,1,1) era el de mejores resultados para la predicción de CEE.

Meira de Oliveira y Cyrino Oliveira [57] en 2018, propusieron evaluar varios modelos para pronosticar el consumo mensual de energía eléctrica utilizando *Bagging*, Arima y un suavizado exponencial como *Holt-Winters*. La serie de tiempo de consumos de energía eléctrica fue descompuesta en componentes más simples utilizando la técnica *Seasonal-Trend Decomposition using Loess (STL Decomposition)*, la cual permitió obtener las series de tendencia, la estacional y la de componentes remanentes. El modelo propuesto fue probado utilizando distintas parametrizaciones para Canadá, Francia, Italia, Japón, Brasil, México y Turquía comprobándose su superioridad respecto a otros modelos como SVM y ANN con los cuales fue comparado.

## 1.6 Genetic Fuzzy System (GFS)

### 1.6.1 Largo plazo

Dalfard *et al.* [54] en 2013, propusieron un modelo GFS que incorporaba el efecto del aumento de los precios de energía con el fin de pronosticar el consumo anual de energía eléctrica de Irán. Como variables de entrada utilizaron la información histórica de trece años desde 1997 hasta 2009, el precio de la energía en todos los sectores económicos, el precio de gas natural en todos los sectores económicos, el GDP, la población del país, la electricidad generada por fuentes renovables y la eficiencia promedio de la generación de electricidad por medio del gas natural. Como resultado del estudio, demostraron que el modelo propuesto podría adoptarse en situaciones donde los precios de la energía aumentasen repentinamente y además se podrían extraer reglas de experto para formar una base de reglas difusa.

## 1.7 Grey Model (GM)

### 1.7.1 Largo plazo

Kumar y Jain [21] en 2010, evaluaron el uso de un modelo *Grey-Model with Rolling Mechanism* denominado GMRM para el pronóstico del consumo anual de energía

eléctrica de India. Para su entrenamiento, utilizaron una matriz de consumos de energía eléctrica con cinco *lags*. El error de entrenamiento medido con la métrica MAPE fue de 3,4 %. Finalmente, para su evaluación hicieron dos predicciones: una para los años 2004-2005 y otra para los años 2005-2006, obteniéndose una precisión del 96,9 % y 95,1 % respectivamente y demostrando que el modelo propuesto tenía aplicación para dichos pronósticos.

En 2011 Lee y Tong [25], propusieron mejorar el modelo GM utilizando el método *Residual Sign Estimation* a través de la programación genética. Como datos de entrenamiento, utilizaron el consumo histórico de energía eléctrica de China desde 1990 hasta 2003 y construyeron un *dataset* con dos *lags* de consumo eléctrico. Al final compararon el modelo propuesto con otros tres como: GM (1,1), el propuesto por Hsu y Chen y un modelo de regresión lineal, a través de la métrica de error MAPE. Pudieron así verificar que el modelo propuesto era igual de preciso que el modelo de Hsu y Chen y mejor que los modelos GM (1,1) y el de regresión lineal.

## 1.8 Genetic Programming (GP)

### 1.8.1 Largo plazo

Azadeh y Tarverdian [30] en 2007, propusieron un modelo utilizando GP para pronosticar los consumos de energía mensual al que entrenaron con información histórica de consumos de energía de marzo de 1994 a febrero del 2005. A través de la métrica de error MAPE, lo compararon con otros de ANN demostrando su superioridad en la precisión de la predicción.

Un año después, Karabulut *et al.* [37], plantearon el uso de un modelo de GP para pronosticar el consumo anual de energía eléctrica de un área del sur de Turquía. Para su validación, construyeron dos modelos de regresión adicionales: el modelo *Polynomial* y el modelo *Power Equation*, donde a través de la métrica MSE determinaron que el modelo propuesto era superior.

Castelli *et al.* en 2015 [10], propusieron cuatro modelos utilizando GP con muestras pasadas de CEE y de información climática, con el objetivo de superar las falencias que en función a su investigación previa detectaron en algunos modelos, ya sea porque se detenían en un local óptimo al momento de entrenarlos o porque no manejaban la no linealidad de los datos. Como resultado, obtuvieron que el uso de un modelo híbrido en lugar de un modelo con operadores estándares aceleraba la convergencia del proceso de búsqueda sin sobreentrenar el modelo y con resultados aceptables.

## 1.9 Regression Model (RM)

### 1.9.1 Corto plazo

En 2017 Amber *et al.* [50], presentaron un modelo de RM para pronosticar el consumo diario de energía eléctrica de un edificio del sector universitario. Durante su desarrollo consideraron las siguientes variables: ECC, temperatura ambiente, radiación solar, humedad relativa, velocidad del viento, tipo de día y tipo de edificio. Para la validación del modelo usaron dos *datasets*, uno con la información de un edificio académico y el otro, con la de un edificio administrativo. Midieron la precisión con la métrica NRMSE. Los resultados obtenidos les permitieron demostrar que realmente las variables que aportaban mayor precisión eran la temperatura, el tipo de día y el tipo de edificio, ya que la velocidad del viento no aportaba diferencia en la precisión del pronóstico y en cuanto a la humedad y la radiación solar, como estaban correlacionadas con la temperatura, no era necesario incluirlas.

### 1.9.2 Largo plazo

Al-Garni *et al.* [31] en 1994, investigaron y desarrollaron un modelo de tipo RM para pronosticar los consumos mensuales de energía eléctrica de Arabia Saudita del Este. Como *dataset* de entrenamiento, utilizaron cinco años de historia con las siguientes variables: humedad relativa, radiación solar, temperatura, población. Para la validación del modelo propuesto realizaron un análisis residual.

En 2012 Adom y Bekoe [38], propusieron dos modelos de pronóstico de tipo RM que denominaron *Partial Adjustment Model (PAM)* y *Autoregressive Distributed Lag Model (ADRL)* para pronosticar el consumo anual de energía eléctrica para Ghana. Como variables de entrada al modelo consideraron las siguientes: EEC, GDP, GDP per cápita, grado de urbanización y eficiencia industrial. Los modelos fueron comparados con otros modelos de RM y concluyeron que, en cuanto a velocidad, el modelo PAM era el más rápido, pero en cuanto a precisión el modelo ADRL era el mejor. Además, el estudio reveló que existía una relación de equilibrio a largo plazo entre las variables de consumo de electricidad, la eficiencia de la industria, la urbanización y el GDP.

En 2014 Ardakani y Ardehali [2], desarrollaron y compararon varios modelos optimizados de regresión y ANN con el fin de determinar cómo la entrada de diferentes tipos de datos históricos afectaba los pronósticos de CEE y así poder pronosticar con ellos el consumo de energía eléctrica a largo tiempo de Irán y Estados Unidos. Los datos considerados fueron CEE y los indicadores GDP, IMP, EXP, y POP. Para optimizar las formas lineales y cuadráticas de los modelos de regresión, examinaron tres algoritmos

de optimización: GD, PSO e IPSO. Concluyeron que independientemente del tipo de economía los pronósticos de CEE a largo tiempo basados en el modelo IPSO-ANN que utilizaba los datos socioeconómicos históricos eran más precisos.

## 1.10 Support Vector Machine (SVM)

### 1.10.1 Corto plazo

Petkovic *et al.* [53] desarrollaron en 2009, un modelo de SVM que utilizaba el algoritmo PSO en su entrenamiento para pronosticar el consumo de energía eléctrica en una empresa refinadora de petróleo. Como variables de entrada al modelo consideraron las siguientes: petróleo refinado diario, uso diario de las unidades industriales, tipo de petróleo refinado, consumos diarios de energía eléctrica y combustibles fósiles usados en el proceso de refinamiento y condiciones climáticas de la temporada. Para su evaluación y comparación, pronosticaron con varios modelos de SVM con distintos *kernels* con y sin el algoritmo PSO. Encontraron que los que utilizaban el algoritmo PSO mejoraban la precisión del pronóstico y, particularmente, el modelo que usaba el *kernel* RBF era el mejor con un error MAPE de 1,4646 %.

Jain *et al.* [23] en 2014, propusieron pronosticar el consumo de un edificio de la ciudad de Nueva York utilizando la información de consumos de energía eléctrica, la radiación solar y temperatura capturada por varios sensores distribuidos por todo el edificio. Como modelo de pronóstico, optaron por utilizar el método de SVM y considerar otras variables de entrada como el tipo de día (semana o fin de semana) y el seno y coseno de la hora. Para la validación del modelo, probaron distintas configuraciones combinando pronósticos cada diez minutos, por hora y diario y varios escenarios espaciales. Encontraron que la mejor combinación era pronosticar por pisos completos del edificio y con una granularidad horaria.

Zhang *et al.* [36] en 2016, presentan dos modelos de SVM, uno utilizaba el parámetro *epsilon* y el otro el parámetro *nu*, combinados ambos con el algoritmo DE para determinar sus parámetros de configuración y los pesos de los modelos. Usando como variable de entrada un *dataset* con el consumo histórico de un año de energía eléctrica de un edificio de Singapur, pronosticaron el consumo con una granularidad de treinta minutos y diaria. Para validar los dos modelos, los compararon contra otras tres variantes de modelos SVM y obtuvieron que los modelos propuestos los superaban. También pudieron observar que para el pronóstico de treinta minutos su error MAPE era 3,767 % y el valor del peso del parámetro *nu* era alto, mientras que para el pronóstico diario, su error MAPE era 5,843 % y el valor alto del peso *epsilon*.

## 1.10.2 Largo plazo

Los autores Zhang y Rui [48] en 2007, compararon dos modelos SVM para pronosticar el consumo de energía eléctrica anual de China. El primer modelo fue de tipo univariado y utilizaba como variable de entrada los datos históricos de consumos de energía de 1985 a 2005. Por el contrario, el segundo modelo fue de tipo multivariado y además consideró las siguientes variables de entrada: GDP per cápita, HIS y EIS. Como conclusión demostraron que el modelo que consideraba las variables socio-macroeconómicas mejoraba la precisión del pronóstico.

## 1.11 Híbridos (H)

### 1.11.1 Corto plazo

Li y Su [35] desarrollaron en 2010, un modelo híbrido denominado *Genetic Algorithm-Hierarchical Adaptive Network-Based Fuzzy Inference System* (GA-Hanfis), el cual utilizaba un algoritmo genético con una red jerárquica adaptativa basada en un sistema de inferencia difusa que disminuía la dimensión de las reglas base. Lo utilizaron para pronosticar el consumo diario de energía eléctrica del aire acondicionado de un hotel a partir de los datos históricos de consumo de energía eléctrica y temperatura. Para validarlo, lo compararon usando la métrica CV contra otros modelos de ANN y GFS pudiendo comprobar la superioridad de este.

Un año más tarde los autores Li *et al.* [28], plantearon un modelo híbrido que combinaba una ANN con un GFS para pronosticar el consumo mensual de energía eléctrica de un edificio y lo compararon contra un modelo tradicional de ANN de tipo FF con una sola capa oculta. Para la validación de este, utilizaron dos *datasets* con distintas variables, para el primero, temperatura, radiación solar, humedad y velocidad del viento y, el segundo solo la temperatura y la cantidad de ocupantes del edificio. Después de realizar cinco ejecuciones por cada *dataset*, finalmente obtuvieron que el modelo propuesto era superior y además se ejecutaba prácticamente en el mismo tiempo que el modelo de ANN.

En 2015 Lü *et al.* [32], propusieron un nuevo método basado en un enfoque físico-estadístico diseñado para tener en cuenta la heterogeneidad y complejidad de los edificios con el fin de mejorar la precisión del pronóstico. Dicho modelo híbrido estaba compuesto por un método físico, un modelo Arima, una SVD y un método *Convex Hull* de bases teóricas similares a las SVM. Compararon el modelo propuesto con dos modelos de SVM, uno lineal y otro no lineal, usando para el no lineal la función RBF. Para su entrenamiento y validación, emplearon información de cuatro edificios de Finlandia obteniendo resultados ellos satisfactorios.

### 1.11.2 Largo plazo

Los autores Meng *et al.* [41], publicaron un artículo en 2011 con un modelo híbrido que descomponía la serie de tiempo usando la técnica DWT en series de tiempos más simples. Como resultado obtuvieron una serie de tendencia pronosticada con un modelo GM y las series de frecuencia periódicas pronosticadas con un modelo ANN de tipo RBF. Finalmente unieron resultados para obtener el pronóstico mensual de consumos de energía. Como *dataset* de entrenamiento, tomaron la información de consumos de energía de China desde enero de 1990 hasta diciembre del 2016 obtenida del sitio web *Chinese Economic and Financial Database of the China Center for Economic Research* (CCER). También compararon el modelo propuesto con otros tres modelos utilizando las métricas de error MaxAPE, MAPE, MdAPE y GMARE, resultando ser el mejor solo para las métricas MaxAPE y MAPE.

En 2012 Zhang y Wang [45], propusieron para pronosticar el consumo de energía anual un modelo híbrido denominado FWNN, que combinaba los modelos ANN y GFS y descomponía la serie de entrada de consumos de energía en wavelets. Este modelo tenía como características su rápida convergencia al resultado, su facilidad de implementación y superior capacidad respecto al modelo GM contra el cual fue comparado utilizando la métrica MAPE.

En el mismo año Tang *et al.* [29], desarrollaron un modelo híbrido, que combinaba el EEMD y el LSSVR, con el fin de pronosticar los consumos mensuales de energía eléctrica nuclear de China. El modelo consistía en descomponer la serie de tiempo de CEE en series más simples y predecir dichos componentes por separado para luego obtener la composición del valor de pronóstico final. Como *dataset* de entrenamiento utilizaron la información obtenida de la *Wind Database* con los consumos de energía nuclear de China de marzo del 1993 a enero del 2010. Finalmente, evaluaron y compararon los modelos híbridos EEMD–LSSVR–ADD, EMD–LSSVR–LSSVR y EMD–LSSVR–ADD a través de las métricas RMSE y MAPE contra otros modelos tradicionales como SVR, LSVVR, ANN y Arima, obteniendo como resultado que el mejor era el modelo híbrido EMD–LSSVR–LSSVR.

Por otra parte Tang *et al.* [43], plantearon en el 2015 combinar el método de modelado basado en las características de los datos y utilizaron la técnica *Decomposition and Ensemble* para construir los modelos de pronósticos de CEE de tipo nuclear. Construyeron dos modelos, el primero usaba el conjunto de modelos Arima–LSSVR y el segundo, LVSSVR–LVSSVR. También construyeron y evaluaron los modelos Arima, FNN y LSSVR de forma individual para compararlos contra los propuestos. Como conclusión demostraron que estos eran superiores.

Barack y Sadegh [40] propusieron un modelo híbrido para pronosticar los consumos de energía anual de Irán, el cual combinaba un modelo lineal (Arima) con otro no lineal (GFS) con el fin de obtener las ventajas de ambos. Probaron tres patrones de configuración entre ambas técnicas e identificaron que el mejor patrón era el tercero, que usaba el método *AdaBoost* con la estructura ANFIS de *Genfis3* y el algoritmo de entrenamiento BP. Además, este modelo obtuvo mejores resultados medidos con la métrica de error MSE, contra otros modelos como *Single Arima*, *Single ANFIS*, *ANN*, *Zhang*, *Khashei and Bijari* y *Babu and Reddy*.

## 1.12 Otros

### 1.12.1 Corto y largo plazo

Singh y Yassine [51], propusieron en 2018 un novedoso modelo que utilizaba minería de datos a través de análisis de patrones frecuentes en series de tiempo de energía, y una técnica de *clustering* no supervisada para obtener las reglas de asociación que serían el insumo y poder pronosticar los resultados utilizando un modelo de redes bayesianas. Para el entrenamiento, crearon un *dataset* sintético a partir del *dataset* real *ISSDA-The Irish Social Science Data Archive* con series de tiempo de consumos de energía de veintiún artefactos eléctricos de una casa con una resolución de un minuto. Para la evaluación de dicho modelo utilizaron dos *datasets* reales, el *dataset UK-DALE* con la serie de tiempos de consumos de energía de 109 artefactos eléctricos recolectado de cinco casas del sur de Inglaterra, con una resolución de tiempo de seis segundos y el *dataset AMPds2-Almanac of Minutely Power* con las series de tiempo de consumos de electricidad, agua y gas natural con una resolución de un minuto en un hogar residencial de Canadá desde el 2012 al 2014. Finalmente, evaluaron el modelo utilizando distintos tamaños de *datasets* de entrenamiento (25 %, 50 % y 75 % del total de este) tanto para el corto como largo plazo y lo compararon contra otros dos modelos que utilizaban técnicas distintas, SVM y ANN con configuración MLP obteniendo como resultado la superioridad del modelo propuesto sobre estos en todos los casos.

## 2. HALLAZGOS Y RESULTADOS

En esta sección se presentan diferentes análisis descriptivos obtenidos a partir de los artículos seleccionados. En la figura 2 se visualiza la distribución de los artículos por tipo de técnica/modelo de pronóstico. Como se puede apreciar, la técnica/modelo más usada es ANN seguida por los híbridos y Arima.

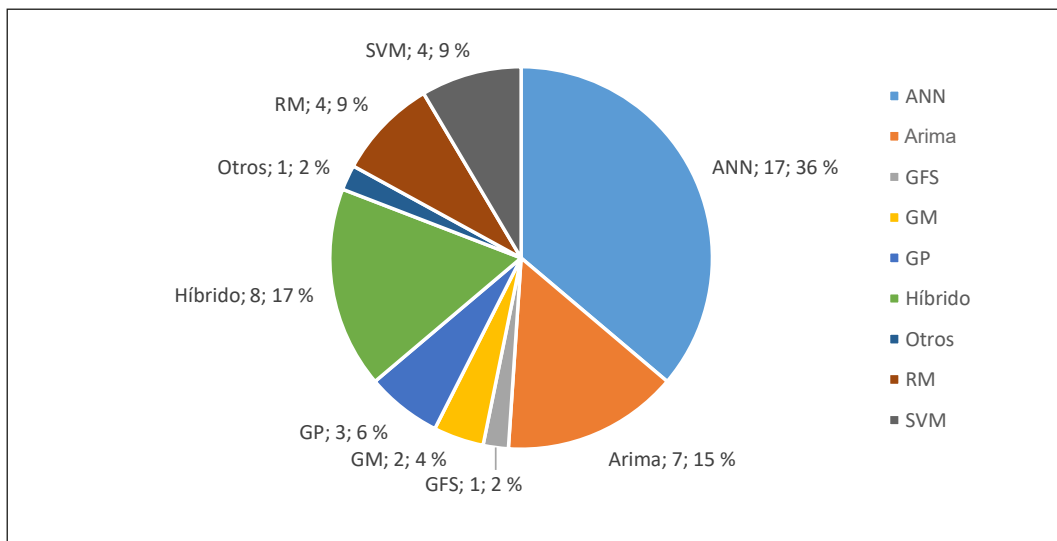


Figura 2. Distribución de artículos por modelo/técnica de pronóstico

Fuente: elaboración propia

En la figura 3 se grafica la distribución de los artículos de acuerdo con la escala de tiempo. Permite visualizar que la mayoría de ellos corresponden a pronósticos de largo plazo.

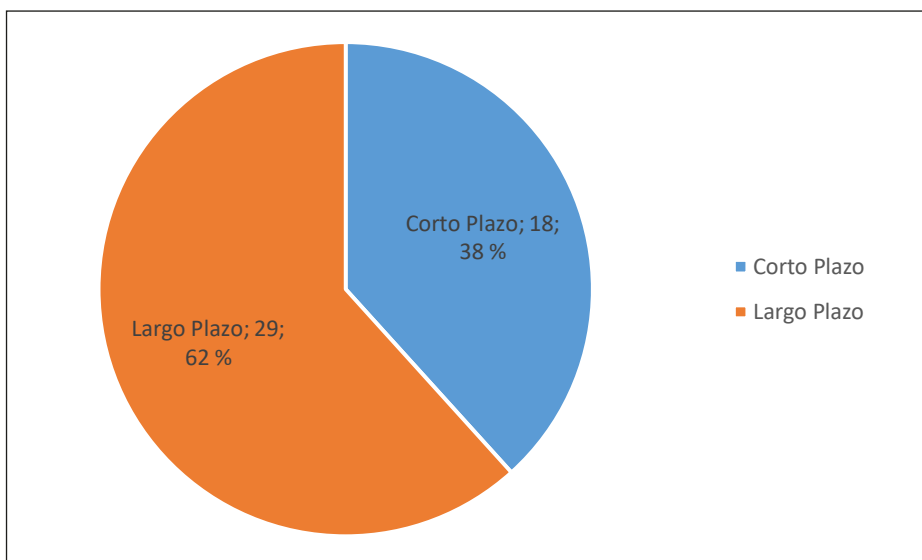


Figura 3. Distribución de artículos por escala de tiempo

Fuente: elaboración propia



A continuación, se presentan los resúmenes de los artículos clasificados según las siguientes características: modelos, variables utilizadas y métodos de error. En las tablas 5 y 6 se exponen los resúmenes de las características de los artículos de pronóstico de corto y largo plazo respectivamente.

Tabla 5. Resumen artículos pronósticos corto plazo.

Referencias	[20]	[23]	[28]	[32]	[35]	[36]	[39]	[44]	[47]	[49]	[50]	[51]	[16]	[52]	[53]	[55]	[58]	[17]
<b>Modelos</b>																		
ANN	P	X	X	X	P	X	P	X	P	X	P	X	P	X	P	P	P	
Arima								P	P					P				
H			P	P														
RM							X				P							
SVM		P	X	P								X	X	X	P			
Otros			P									P	X					
<b>Variables</b>																		
Día																X	X	
CEE		X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
FH	X	X								X			X					
Hora		X				X										X	X	
RS	X	X	X										X					
T	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
Tipo día	X	X				X				X								
WS			X							X		X	X					
Otras			X	X		X	X			X	X	X	X	X				
<b>Métodos de error</b>																		
CV		X	X	X														
MAE					X													
MAPE	X				X	X	X			X	X		X	X	X			
ME					X		X											
MSE			X						X									
R			X			X									X			
RMSE					X	X			X		X					X		
Otros						X	X			X					X	X	X	

P: Modelo propuesto – X: Modelo comparación

Fuente: elaboración propia

Tabla 6. Resumen artículos pronósticos largo plazo.

<i>Referencias</i> [21][22][24][25][26][27][29][30][31] [2] [33] [8] [34][37][38][40][41] [42] [5] [43][45][10][46][48][54] [4] [56][57][59]																						
<b>Modelos</b>																						
ANN	P	P		P	X	X		X	P	X	P		X	X	P	X		P	P	X	P	
Arima				P	X	X			P				X	P					X	X	P	
GFS													X						P			
GM	P		P																	X		
GP						P				P										P		
H						P							P	P					P	P		
RM		X	X				P	P					P								X	
SVM						X				X									X	P		X
<b>Variables</b>																						
Año									X						X							
CEE	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X
EXP							X						X									
FH							X														X	
GDP							X		X	X	X		X						X	X		
IMP							X		X		X		X									
POP							X	X	X				X	X						X		
Fuel Price	X																					
Energy Price	X																				X	
RS							X															
T							X		X										X		X	
WS																				X		
Otras	X							X		X									X	X	X	X
<b>Métodos de error</b>																						
APE		X											X						X	X		
D <sub>stat</sub>							X								X							
MAE	X	X		X	X								X	X		X					X	
MAPE	X	X	X	X		X	X	X	X				X	X	X	X	X	X	X	X	X	X
MSE	X		X	X					X	X		X		X		X						

Referencias	[21]	[22]	[24]	[25]	[26]	[27]	[29]	[30]	[31]	[2]	[33]	[8]	[34]	[37]	[38]	[40]	[41]	[42]	[5]	[43]	[45]	[10]	[46]	[48]	[54]	[4]	[56]	[57]	[59]
R											X				X										X				X
RMSE		X				X					X										X						X	X	X
Otros			X	X			X					X				X	X												X

P: Modelo propuesto – X: Modelo comparación

Fuente: elaboración propia

### 2.1 Publicaciones y año de publicación

La figura 4 muestra la cantidad de publicaciones de artículos y su evolución por año para las diferentes escalas de tiempo de los pronósticos y para la suma de ambos, donde claramente se puede identificar que es un tema que se sigue desarrollando en la actualidad.

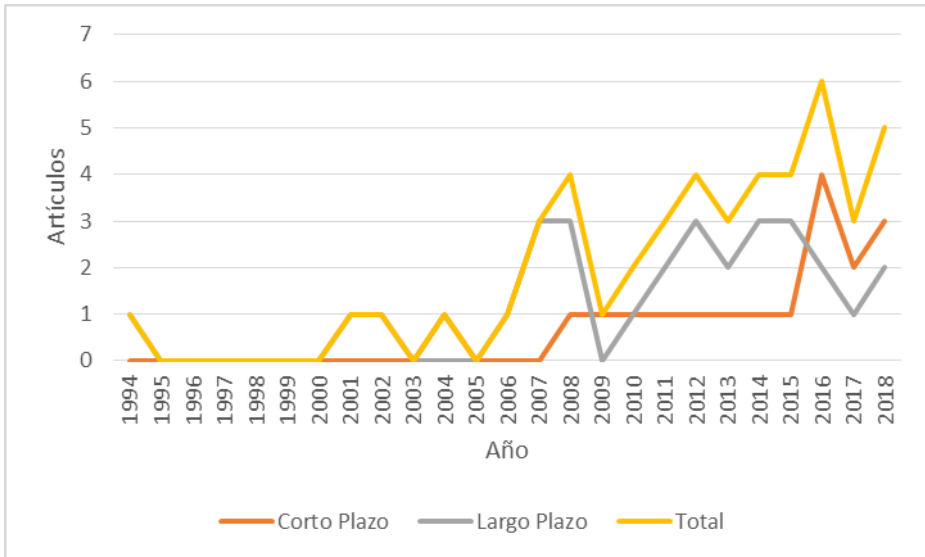


Figura 4. Publicación de artículos por año por escala de tiempo del pronóstico

Fuente: elaboración propia

### 2.2 Modelos usados

En la tabla 7 se observa que el modelo de ANN es el más usado para la construcción de las soluciones de pronósticos, independientemente de la escala de tiempo a predecir. A este le siguen los modelos de Arima e híbridos, los cuales se usan casi con el mismo porcentaje en corto y largo plazo.

Tabla 7. Modelos propuestos en los artículos por escala de tiempo del pronóstico

Escala/Modelo	ANN	Arima	GFS	GM	H	RM	SVM	Otros
Corto plazo	7	3	0	0	3	1	3	1
Largo plazo	10	4	1	2	5	3	1	0
Total	17	7	1	2	8	4	4	1

Fuente: elaboración propia

### 2.3 Variables de entrada

Para los pronósticos de corto y de largo plazo, la variable más utilizada es el CEE como lo indican las figuras 5 y 6 respectivamente.

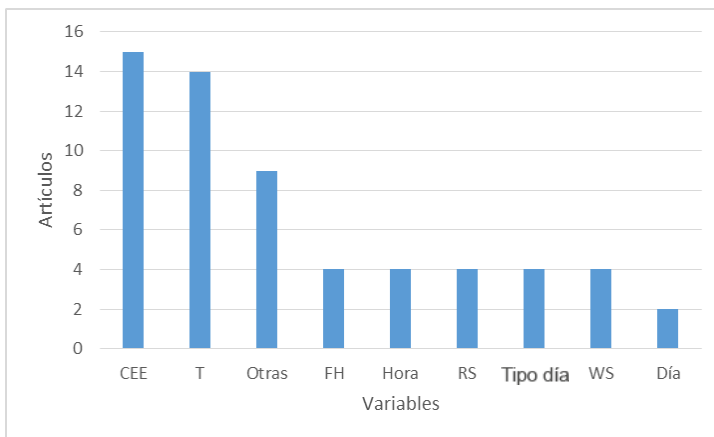


Figura 5. Ranking de variables utilizadas en pronósticos de corto plazo

Fuente: elaboración propia

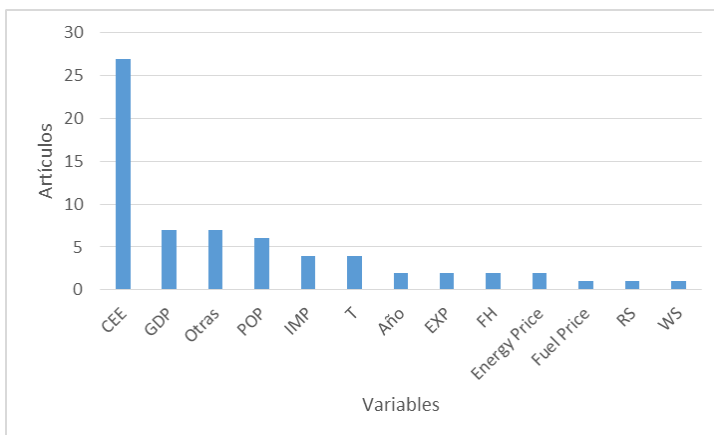


Figura 6. Ranking de variables utilizadas en pronósticos de largo plazo

Fuente: elaboración propia

## 2.4 Métodos/Técnicas de error

Para el cálculo de la precisión de los modelos propuestos, la técnica de error MAPE es la más utilizada (figura 7) independiente de la escala de tiempo.

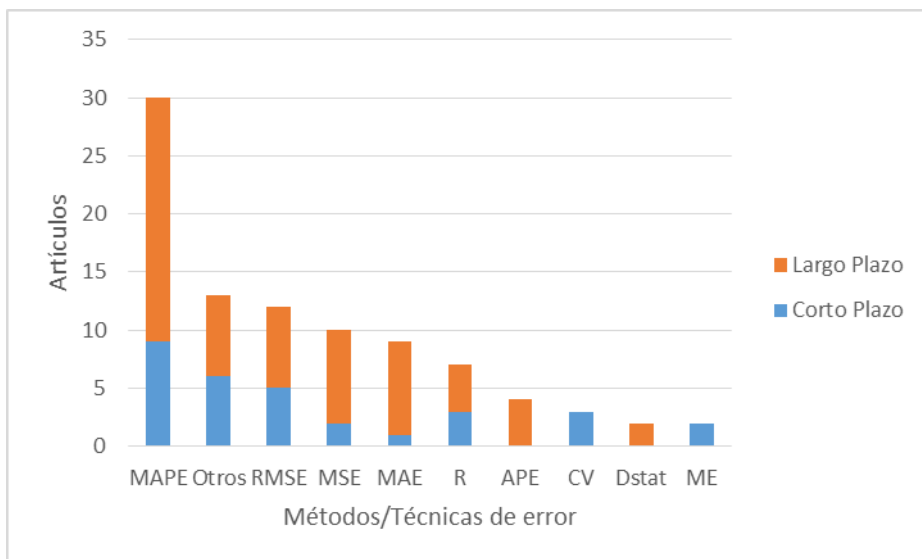


Figura 7. Ranking de métodos/técnicas para el cálculo de error en los modelos de pronóstico

Fuente: elaboración propia

## 3. DISCUSIÓN

Todas las soluciones propuestas en los artículos revisados se han aplicado con éxito para la predicción del CEE en sus respectivos contextos. Cada técnica posee ciertas características que deben aplicarse adecuadamente al caso de estudio.

Si bien, como muestra en la figura 3, el 60 % de los artículos revisados corresponde a pronósticos de largo plazo, cabe señalarse la tendencia creciente de artículos de corto plazo en los últimos años (figura 5), conjuntamente la tendencia creciente de ambos, lo cual muestra que el tema sigue siendo de interés para la investigación en la actualidad.

Con relación a los modelos empleados, se observa que independientemente de la escala de tiempo considerada, el ANN es el más usado debido a que tiene más ventajas que los modelos estadísticos por su versatilidad y capacidad de generar la relación de entrada y salida, sin hacer compleja la dependencia con las variables de entrada. Por su parte, los modelos basados en Arima muestran una leve preeminencia en los pronósticos de largo plazo, mientras que GFS y GM no tienen aplicación en el corto plazo. Cabe mencionar que varios autores proponen la utilización de modelos

híbridos o un conjunto de modelos para superar las desventajas de cada modelo, por ejemplo, la combinación de una técnica lineal con una no lineal. Un claro ejemplo es la utilización de un modelo ANN con un algoritmo que ayuda a calcular los pesos iniciales de los nodos, evitando que queden en un mínimo local y que resulten de convergencia lenta. Es importante resaltar que, aunque las ANN sean el modelo más utilizado en los artículos revisados, no es suficiente evidencia para afirmar que es el mejor, debido a que en las contrastaciones, debería utilizarse el mismo conjunto de datos y, al mismo tiempo, medirse la precisión de los resultados utilizando la misma técnica para el cálculo del error. Otras diferencias que se evidencian es el no uso de las mismas técnicas/modelos en las distintas escalas de tiempo y que el método Arima solo aplica para pronósticos de tipo univariados.

Respecto a las variables de entrada, la más utilizada en todas las soluciones propuestas independientemente de sus características específicas es el CEE. A fin de redundar en mejores resultados, en los estudios de corto plazo la variable complementaria de mayor recurrencia es la temperatura, mientras que en los de largo plazo lo son las variables macroeconómicas como GDP y POP.

Si bien mayoritariamente el error es medido con MAPE, en un 60 % de los artículos se implementó un conjunto de otras técnicas, tales como RSME, MSE y MAE, para dar mayor fiabilidad y validación a los modelos.

Finalmente, la metodología de investigación/trabajo se basó mayoritariamente en casos de estudio aplicados, debido a la importancia actual de poder contar con una herramienta de pronóstico para resolver los distintos problemas planteados.

#### **4. CONCLUSIONES**

En este trabajo se revisaron artículos de la literatura sobre propuestas de modelos de pronósticos para el CEE, donde se identificaron las ventajas y desventajas en cada uno de ellos según se tratase de pronósticos a corto o largo plazo. Entre estas técnicas/modelos, las ANN han ganado la mayor atención de numerosos investigadores debido a su precisión y simplicidad en la construcción. Sin embargo, varios autores proponen tanto modelos híbridos como nuevos que buscan mejorar aún más la precisión de los pronósticos de forma simultánea con la adaptabilidad de este a los cambios de comportamiento de los consumidores de energía eléctrica y la adecuada selección de variables de entrada. Otro punto de importancia es la selección de variables de entrada y su cantidad a ser considerada. En último lugar, se registra la importancia de contar con métricas de cálculo de error como MAPE, ya sea solo o con otras métricas para validar, evaluar y determinar el modelo más efectivo.

A partir del conocimiento obtenido a través de la revisión realizada, se propone como línea de investigación la profundización de modelos para el pronóstico de CEE a corto plazo para un país latinoamericano en vías de desarrollo, comparando y evaluando diferentes técnicas/modelos, variables y herramientas ya existentes con el objetivo proponer el modelo que provea información precisa y confiable para la toma de decisiones a los distintos participantes de la cadena constitutiva del mercado eléctrico, con relación a la planeación y optimización de recursos y preservación del medio ambiente.

## 5. AGRADECIMIENTOS

Los autores quieren agradecer a la Universidad de Medellín y a MVM Ingeniería de *Software* SAS por la disposición del tiempo y los recursos para realizarlo. Finalmente, destacamos que no hubiera sido posible llevar a cabo la realización de este artículo sin el constante apoyo y la comprensión de nuestras familias.

## REFERENCIAS

- [1] C. Yuan, S. Liu y Z. Fang, “Comparison of China’s primary energy consumption forecasting by using Arima (the autoregressive integrated moving average) model and GM (1,1) model”, *Energy*, vol. 100, pp. 384-390, 2016; Disponible: <https://doi.org/10.1016/j.energy.2016.02.001>
- [2] F. J. Ardakan y M. M. Ardehali, “Long-term electrical energy consumption forecasting for developing and developed economies based on different optimized models and historical data types”, *Energy*, vol. 65, pp. 452-461, 2014; Disponible: <https://doi.org/10.1016/j.energy.2013.12.031>
- [3] S. Aghay, J. Selvaraj y N. Rahim, “Long-term electric energy consumption forecasting via artificial cooperative search algorithm”, *Energy*, vol. 115, Part 1, pp. 857-871, 2016; Disponible: <https://doi.org/10.1016/j.energy.2016.09.015>
- [4] M. Meng, W. Shang y D. Niu, “Monthly Electric Energy Consumption Forecasting Using Multiwindow Moving Average and Hybrid Growth Models”, *Journal of Applied Mathematics*, vol. 2014, Article ID 243171, pp. 1-7, 2014; Disponible: <https://doi.org/10.1155/2014/243171>
- [5] Y. R. Zeng, Y. Zeng, B. Choi y L. Wang, “Multifactor-influenced energy consumption forecasting using enhanced back-propagation neural network”, *Energy*, vol 127, pp. 381-396, 2017; Disponible: <https://doi.org/10.1016/j.energy.2017.03.094>
- [6] Y. W. Foo, C. Goh, H. C Lim, Z. Zhan y Y. Li, “Evolutionary Neural Network Based Energy Consumption Forecast for Cloud Computing”. In *2015 International Conference on Cloud Computing Research and Innovation (ICCCRI)*. *IEEE*, pp. 53-64, 2015; Disponible: <https://doi.org/10.1109/ICCCRI.2015.17>
- [7] A. Jozi, T. Pinto, I. Praca, F. Silva, B. Teixeira y Z. Vale Z, “Energy consumption forecasting based on Hybrid Neural Fuzzy Inference System”, In *2016 IEEE Symposium Series on*

- Computational Intelligence (SSCI). IEEE*, pp. 1-5, 2016; Disponible: <https://doi.org/10.1109/SSCI.2016.7849859>
- [8] L. Tang, L. Yu y K. He, “Novel data-characteristic-driven modeling methodology for nuclear energy consumption forecasting”, *Applied Energy*, vol. 128, pp. 1-14, 2014; Disponible: <https://doi.org/10.1016/j.apenergy.2014.04.021>
- [9] H. Zhao, S. Guo, “Annual Energy Consumption Forecasting Based on PSOCA-GRNN Model”, *Abstract and Applied Analysis*, vol. 2014, Article ID 217630, pp.1-11, 2014; Disponible: <https://doi.org/10.1155/2014/217630>
- [10] M. Castelli, L. Trujillo y L. Vanneschi, “Energy Consumption Forecasting Using Semantic-Based Genetic Programming with Local Search Optimizer”, *Computational Intelligence and Neuroscience*, vol. 2015, Article ID 971908, p. 8, 2015; Disponible: <https://doi.org/10.1155/2015/971908>
- [11] K. M. Ahmed, M. A. Amin y M. T. Rahman, “Application of short term energy consumption forecasting for household energy management system” In *2015 3rd International Conference on Green Energy and Technology (ICGET). IEEE*, pp. 1-6; Disponible: <https://doi.org/10.1109/ICGET.2015.7315095>
- [12] M. Taborda, J. Almeida, J. A. Oliveir-Lima y J. F. Martins, “Towards a web-based energy consumption forecasting platform”, In *2015 9th International Conference on Compatibility and Power Electronics (CPE). IEEE*, pp. 577-580; Disponible: <https://doi.org/10.1109/CPE.2015.7231140>
- [13] V. N. Denizcan, M. O. Sayin, H. Yildiz, T. Goze y S. Kozat, “Energy consumption forecasting via order preserving pattern matching”, In *2014 IEEE Global Conference on Signal and Information Processing (GlobalSIP). IEEE*, pp. 238-242; Disponible: <https://doi.org/10.1109/GlobalSIP.2014.7032114>
- [14] A. Jozi, T. Pinto, I. Praca, F. Silva, B. Teixeira y Z. Vale Z, “Wang and Mendel’s fuzzy rule learning method for energy consumption forecasting considering the influence of environmental temperature”, In *2016 Global Information Infrastructure and Networking Symposium (GIIS). IEEE*, pp. 1-6; Disponible: <https://doi.org/10.1109/GIIS.2016.7814944>
- [15] A. Jozi, T. Pinto, I. Praca, F. Silva, B. Teixeira y Z. Vale, “Energy consumption forecasting using genetic fuzzy rule-based systems based on MOGUL learning methodology”, In *2017 IEEE Manchester PowerTech. IEEE*, pp. 1-5; Disponible: <https://doi.org/10.1109/PTC.2017.7981219>
- [16] R. D. Wang, X. S. Sun, X. Yang y H. Hu, “Cloud Computing and Extreme Learning Machine for a Distributed Energy Consumption Forecasting in Equipment-Manufacturing Enterprises”, *Cybernetics and Information Technologies*, vol. 16, Issue 6, pp. 83-97, 2016; Disponible: <https://doi.org/10.1515/cait-2016-0079>
- [17] B. A. Staroverov y B. A. Gnatyuk, “Universal energy consumption forecasting system based on neural network ensemble”, *Optical Memory and Neural Networks*, vol. 25, Issue 3, pp. 198-202, 2016; Disponible: <https://doi.org/10.3103/S1060992X16030097>



- [18] D. Tranfield, D. Denyer y P. Smart, “Towards a Methodology for Developing Evidence-Informed Management Knowledge by Means of Systematic Review”, *British Journal of Management*, vol. 14, Issue 3, pp. 207-222, 2003; Disponible: <https://doi.org/10.1111/1467-8551.00375>
- [19] D. Denyer, D. Tranfield, Producing a systematic review. In *The Sage Handbook of Organizational Research Methods*, SAGE Publications Ltd., ISBN 9781446246054, pp. 671–689, 2009.
- [20] N. A. Hernandez y F. F. Sanzovo, “Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption”, *Energy and Buildings*, vol. 40, Issue 12, pp. 2169-2176, 2008; Disponible: <https://doi.org/10.1016/j.enbuild.2008.06.013>
- [21] U. Kumar y V. K. Jain, “Time series models (Grey-Markov, Grey Model with rolling mechanism and singular spectrum analysis) to forecast energy consumption in India”, In *Energy, Elsevier*, vol. 35, Issue 4, pp. 1709-1716, 2010; Disponible: <https://doi.org/10.1016/j.energy.2009.12.021>
- [22] A. Azadeh, S. F. Ghaderi y S. Sohrabkhani, “Annual electricity consumption forecasting by neural network in high energy consuming industrial sectors”, *Energy Conversion and Management*, vol. 49, Issue 8, pp. 2272-2278, 2008; Disponible: <https://doi.org/10.1016/j.enconman.2008.01.035>
- [23] Jain R. K., Smith, K. M., P. J. Culligan y J. E. Taylor, “Forecasting energy consumption of multi-family residential buildings using support vector regression: Investigating the impact of temporal and spatial monitoring granularity on performance accuracy”, *Applied Energy*, vol. 123, pp. 168-178, 2014; Disponible: <https://doi.org/10.1016/j.apenergy.2014.02.057>
- [24] C. Hamzacebi, “Forecasting of Turkey’s net electricity energy consumption on sectoral bases”, *Energy Policy*, vol. 35, Issue 3, pp. 2009-2016, 2007; Disponible: <https://doi.org/10.1016/j.enpol.2006.03.014>
- [25] Y. S. Leey L. I. Tong, “Forecasting energy consumption using a grey model improved by incorporating genetic programming”, *Energy Conversion and Management - ENERGY CONV MANAGE*, vol. 52, Issue 1, pp. 147-152, 2011; Disponible: <https://doi.org/10.1016/j.enconman.2010.06.053>
- [26] S. Saab, E. Badr y G. Nasr, “Univariate modeling and forecasting of energy consumption: the case of electricity in Lebanon”, *Energy, Elsevier*, vol. 26, Issue 1, pp. 1-14, 2001; Disponible: [https://doi.org/10.1016/S0360-5442\(00\)00049-9](https://doi.org/10.1016/S0360-5442(00)00049-9)
- [27] A. Azadeh, S. F. Ghaderi y S. Sohrabkhani, A simulated-based neural network algorithm for forecasting electrical energy consumption in Iran. *Energy Policy*, vol. 36, Issue 7, pp. 2637-2644, 2008; Disponible: <https://doi.org/10.1016/j.enpol.2008.02.035>
- [28] K. Li, H. Suy J. Chu, “Forecasting building energy consumption using neural networks and hybrid neuro-fuzzy system: A comparative study”, *Energy and Buildings*, vol. 43, Issue 10, pp. 2893-2899, 2011; Disponible: <https://doi.org/10.1016/j.enbuild.2011.07.010>

- [29] L. Tang, L. Yu, S. Wang, J. Li y S. Wang “A novel hybrid ensemble learning paradigm for nuclear energy consumption forecasting”, *Applied Energy*, vol. 93, pp. 432-443, 2012; Disponible: <https://doi.org/10.1016/j.apenergy.2011.12.030>
- [30] A. Azadeh y S. Tarverdian “Integration of genetic algorithm, computer simulation and design of experiments for forecasting electrical energy consumption”, *Energy Policy*, vol. 35, Issue 10, pp. 5229-5241, 2007; Disponible: <https://doi.org/10.1016/j.enpol.2007.04.020>
- [31] A. Z. Al-Garni, S. N. Zubair y J. S. Nizami, “A regression model for electric-energy-consumption forecasting in Eastern Saudi Arabia”, *Energy*, vol. 19, Issue 10, pp. 1043-1049, 1994; Disponible: [https://doi.org/10.1016/0360-5442\(94\)90092-2](https://doi.org/10.1016/0360-5442(94)90092-2)
- [32] X. Lü, T. Lu, C. J. Kibert y M. Viljanen, “Modeling and forecasting energy consumption for heterogeneous buildings using a physical–statistical approach”, *Applied Energy*, vol. 144, pp. 261-275, 2015; Disponible: <https://doi.org/10.1016/j.apenergy.2014.12.019>
- [33] A. Sözen, M. A. Akçayol, y E. Arcaklioğlu, “Forecasting Net Energy Consumption Using Artificial Neural Network”, *Energy Sources, Part B: Economics, Planning, and Policy*, vol. 1, Issue 2, pp. 147-155, 2006; Disponible: <https://doi.org/10.1080/009083190881562>
- [34] G. E. Nasr, E. A. Badr, y M. R. Younes, “Neural networks in forecasting electrical energy consumption: univariate and multivariate approaches”, *International Journal of Energy Research*, vol. 26, Issue 1, pp. 67-78, 2002; Disponible: <https://doi.org/10.1002/er.766>
- [35] K. Li y H. Su, “Forecasting building energy consumption with hybrid genetic algorithm-hierarchical adaptive network-based fuzzy inference system”, *Energy and Buildings*, vol. 42, Issue 11, pp. 2070-2076, 2010; Disponible: <https://doi.org/10.1016/j.enbuild.2010.06.016>
- [36] F. Zhang, C. Deb, S. E. Lee, J. Yang y K. W. Shah, “Time series forecasting for building energy consumption using weighted Support Vector Regression with differential evolution optimization technique”, *Energy and Buildings*, vol. 126, pp. 94-103, 2016; Disponible: <https://doi.org/10.1016/j.enbuild.2016.05.028>
- [37] K. Karabulut, A. Alkan y A. Yilmaz, “Long Term Energy Consumption Forecasting Using Genetic Programming”, *Mathematical and Computational Applications*, vol. 13, Issue 2, pp. 71-80, 2008; Disponible: <https://doi.org/10.3390/mca13020071>
- [38] P. K. Adom y W. Bekoe, “Conditional dynamic forecast of electrical energy consumption requirements in Ghana by 2020: A comparison of ARDL and PAM”, *Energy*, vol. 44, Issue 1, pp. 367-380, 2012; Disponible: <https://doi.org/10.1016/j.energy.2012.06.020>
- [39] D. Baczynski y M. Parol, “Influence of artificial neural network structure on quality of short-term electric energy consumption forecast”, In *IEE Proceedings - Generation, Transmission and Distribution*, vol. 151, Issue 2, pp. 241-245, 2004; Disponible: <https://doi.org/10.1049/ip-gtd:20040070>
- [40] S. Barak y S. Sadegh, “Forecasting energy consumption using ensemble Arima–ANFIS hybrid algorithm”, *International Journal of Electrical Power & Energy Systems*, Volume 82, pp. 92-104, 2016; Disponible: <https://doi.org/10.1016/j.ijepes.2016.03.012>

- [41] M. Meng, D. Niu y W. Sun “Forecasting Monthly Electric Energy Consumption Using Feature Extraction”, *Energies*, vol.V 4, Issue 10, pp. 1495-1507, 2011; Disponible: <https://doi.org/10.3390/en4101495>
- [42] P. Sen, M. Roy y P. Pal “Application of Arima for forecasting energy consumption and GHG emission: A case study of an Indian pig iron manufacturing organization”, *Energy*, vol. 116, part. 1, pp. 1031-1038, 2016; Disponible: <https://doi.org/10.1016/j.energy.2016.10.068>
- [43] L. Tang, K. He y S. Wang, “A novel mode-characteristic-based decomposition ensemble model for nuclear energy consumption forecasting”, *Annals of Operations Research*, Volume 243, Issue 1, pp. 111-132, 2015; Disponible: <https://doi.org/10.1007/s10479-014-1595-5>
- [44] V. Kamaev, M. Shcherbakov, D. Panchenko, N. L. Shcherbakova y A. Brebels, “Using connectionist systems for electric energy consumption forecasting in shopping centers”, *Automation and Remote Control*, vol. 73, Issue 6, pp. 1075-1084, 2012; Disponible: <https://doi.org/10.1134/S0005117912060124>
- [45] P. Zhang y H. Wang, “Fuzzy Wavelet Neural Networks for City Electric Energy Consumption Forecasting”, *Energy Procedia*, vol. 17, part. B, pp. 1332-1338, 2012; Disponible: <https://doi.org/10.1016/j.egypro.2012.02.248>
- [46] X. Jiang, H. Ling, J. Yan, B. Li y Z. Li, “Forecasting Electrical Energy Consumption of Equipment Maintenance Using Neural Network and Particle Swarm Optimization”, *Mathematical Problems in Engineering*, vol. 2013, Article ID 194730, p. 8, 2013; Disponible: <https://doi.org/10.1155/2013/194730>
- [47] J. Yoo y K. Hur, “Load Forecast Model Switching Scheme for Improved Robustness to Changes in Building Energy Consumption Patterns”, *Energies*, vol. 6, Issue 3, pp. 1329-1343, 2013; Disponible: <https://doi.org/10.3390/en6031329>
- [48] X. P. Zhang y G. Rui, “Electrical Energy Consumption Forecasting Based on Cointegration and a Support Vector Machine in China”, *WSEAS Transactions on Mathematics*, vol. 6, Issue 6, pp. 878-883, 2007; Disponible: <http://dl.acm.org/citation.cfm?id=1486783.1486785>
- [49] L. G. Ruiz, R. Rued, M. P. Cuéllar y M. C. Pegalajar, “Energy consumption forecasting based on Elman neural networks with evolutive optimization”, *Expert Systems with Applications*, vol. 92, pp. 380-389, 2018; Disponible: <https://doi.org/10.1016/j.eswa.2017.09.059>
- [50] K. Amber, M. W. Aslam, A. Mahmood, A. Kousar, M. Younis, B. Akbar, G. Chaudhary y S. K. Hussain, “Energy Consumption Forecasting for University Sector Buildings”, *Energies*, vol. 10, Issue 10, 1579, 2017; Disponible: <https://doi.org/10.3390/en10101579>
- [51] S. Singh y A. Yassine, “Big Data Mining of Energy Time Series for Behavioral Analytics and Energy Consumption Forecasting”, *Energies*, vol. 11, Issue 2, p. 452, 2018; Disponible: <http://doi.org/10.3390/en11020452>
- [52] Y. Zhang, R. Yang, K. Zhang, H. Jiang y J. Zhang, “Consumption Behavior Analytics-Aided Energy Forecasting and Dispatch”, In *IEEE Intelligent Systems*, vol. 32, Issue 4, pp. 59-63, 2017; Disponible: <https://doi.org/10.1109/MIS.2017.3121551>

- [53] M. Petkovic, M. Rapačić y B. Jakovljević, “Electrical Energy Consumption Forecasting in Oil Refining Industry Using Support Vector Machines and Particle Swarm Optimization”, *WSEAS Transactions on Information Science and Applications*, vol. 6, Issue 11, pp. 1761-1770, 2009; Disponible: <http://dl.acm.org/citation.cfm?id=1718140.1718143>
- [54] D. V. Majazi, M. Nazari, S. Nazari-Shirkouhi, S. M. Sajadi y S. Asadzadeh, “Incorporating the effects of hike in energy prices into energy consumption forecasting: a fuzzy expert system”, *Neural Computing and Applications*, vol. 23, Supplement 1, pp. 153-169, 2013; Disponible: <https://doi.org/10.1007/s00521-012-1282-x>
- [55] J. L. Rojas-Renteria, T. D. Espinoza-Huerta, F. S. Tovar-Pacheco, J. L. Gonzalez-Pérez y R. Lozano-Dorantes, “An Electrical Energy Consumption Monitoring and Forecasting System”, *Engineering, Technology & Applied Science Research*, vol. 6, Issue 5, pp. 1130-1132, 2016. Disponible: <https://doi.org/10.5281/zenodo.162580>
- [56] L. Wang, H. Hu, X. Y. Ai y H. Liu, “Effective electricity energy consumption forecasting using echo state network improved by differential evolution algorithm”, *Energy*, vol. 153, pp. 801-815, 2018; Disponible: <https://doi.org/10.1016/j.energy.2018.04.078>
- [57] E. Meira de Oliveira y F. L. Cyrino, “Forecasting mid-long term electric energy consumption through bagging Arima and exponential smoothing methods”, *Energy*, vol. 144, pp. 776-788, 2018; Disponible: <https://doi.org/10.1016/j.energy.2017.12.049>
- [58] M. H. Alobaidi, F. Chebana y M. A. Meguid, “Robust ensemble learning framework for day-ahead forecasting of household based energy consumption”, *Applied Energy*, vol. 212, pp. 997-1012, 2018; Disponible: <https://doi.org/10.1016/j.apenergy.2017.12.054>
- [59] S. Mishra y V. K. Singh, “Monthly Energy Consumption Forecasting Based On Windowed Momentum Neural Network”, *IFAC-PapersOnLine*, vol. 48, Issue 30, pp. 433-438, 2015; Disponible: <https://doi.org/10.1016/j.ifacol.2015.12.417>