

Modelación de la demanda máxima en función de la cantidad de clientes

Alvaro Laurencio Pérez

alvarolaurencio040@gmail.com

Olga Pérez Maliuk

operezm@uho.edu.cu

Universidad de Holguín

Igor R. Pérez Maliuk

Empresa Eléctrica de Holguín

Resumen: Se realizó una modelación para determinar la demanda máxima en función de la cantidad de clientes en circuitos de distribución primaria de la provincia Holguín. Se tuvo en cuenta una modelación matemática, haciendo uso de la herramienta *Cuervexpert 1.3*, y una modelación mediante redes neuronales artificiales haciendo uso del *software* Matlab R2018b, a través del código nntool. En la modelación matemática se obtuvo una curva polinómica con un error estándar de 1,311 y un coeficiente de correlación entre las variables entrada y salida (demanda máxima y cantidad de clientes, respectivamente) de 0,833, mientras que la red neuronal artificial presenta una neurona en la primera y segunda capa oculta, ambas con función logsig, mientras que la capa de salida quedó constituida por una neurona con función transferencia pureline, con error medio cuadrático de $1,23 \cdot 10^{-3}$ y un coeficiente de correlación de 0,840. Ambos modelos obtenidos ofrecen resultados satisfactorios en la modelación de la característica demanda máxima contra cantidad de clientes y ser aplicada a circuitos en localidades donde, entre otras circunstancias, las condiciones económicas no permitan la colocación de equipos de mediciones o existan limitaciones en cuanto al acceso a la información.

Palabras clave: clientes; demanda máxima; error; modelación; red neuronal artificial.

Modeling of maximum demand based on the number of customers

Abstract: A modeling was carried out to determine the maximum demand based on the number of clients in primary distribution circuits in the Holguín province. A mathematical modeling was taken into account, using the Cuervexpert 1,3 tool, and a modeling using artificial neural networks using the Matlab R2018b software, through the nntool code. In the mathematical modeling, a polynomial curve was obtained with a standard error of 1.311 and a correlation coefficient between the input and output variables (maximum demand and number of clients, respectively) of 0,833, while the artificial neural network with the best results presents a neuron in the first and second hidden layer, both with logsig function, while the output layer was constituted by a neuron with pureline transfer function, with mean square error of $1,23 \cdot 10^{-3}$ and a correlation coefficient of 0,840. Both models obtained offer satisfactory results in the modeling of the characteristic maximum demand against number of customers and be applied to circuits in locations where, among other circumstances, economic conditions do not allow the placement of measurement equipment or there are limitations regarding access to services. information.

Keywords: clients; maximum demand; error; modeling; artificial neural network.

Introducción

La variedad de cargas presente en un sistema de distribución es muy amplia, desde las grandes y complejas instalaciones industriales hasta las residencias más pequeñas, las cuales difieren entre sí en magnitud y comportamiento.

Uno de los objetivos básicos que se persigue al evaluar una carga es determinar, entre otros factores, el valor máximo de su demanda, ya que permite la toma de decisiones como el ordenamiento de la capacidad de generación, planificación de consumos, evaluaciones de los márgenes de seguridad y gestión del combustible (Darmanis *et al.*, 2020; Feng *et al.*, 2019; Jang, Byon, Jahani & Cetin, 2020; Shirzadi, Nizami, Khazen & Nik-Bakht, 2021; Zhang *et al.*, 2018). Además, la amplia relación entre la demanda máxima con el consumo de electricidad, la acredita como un factor determinante en el uso eficiente de la energía (Castro, Severiano & Sperandio, 2019; Jang *et al.*, 2020; Popov, Prykhno & Prykhno, 2019).

El incremento de la población a nivel mundial y el surgimiento cada vez más de dispositivos eléctricos, han provocado el aumento acelerado del consumo de energía. Por ello, varias herramientas de simulación, trabajos de ingeniería y la inteligencia artificial, basados en modelos, han sido empleadas para el pronóstico de la demanda para un funcionamiento óptimo del sistema (Al-Musaylh, Deo, Adamowski & Li, 2018; Bedi & Toshniwal, 2019; Galarza, Condezo, Saenz & Huarac, 2021; Jang *et al.*, 2020; Kavadias, Apostolou & Kaldellis, 2018).

El método tradicionalmente empleado para resolver problemas en ingeniería es mediante modelos representados por ecuaciones que intentan reproducir con mayor o menor exactitud, el sistema en cuestión.

La modelación matemática constituye una poderosa herramienta en aras de analizar y predecir el comportamiento de un determinado proceso o sistema (Hung & Michailidis, 2019; Li *et al.*, 2019; Moradi *et al.*, 2020; Sigauke & Nemukula, 2020). Sin embargo, las redes neuronales artificiales figuran entre los acercamientos más populares en la actualidad en medio de los diferentes tipos de modelos (Ghadami *et al.*, 2021; Kim & Cho, 2019; Lu & Hong, 2019; Muralitharan, Sakthivel & Vishnuvarthan, 2018; Runge & Zmeureanu, 2019).

Según Runge & Zmeureanu (2019) en su estudio de revisión de la aplicación de la inteligencia artificial, plantean que en esta área, el pronóstico de energía es ampliamente resaltado.

Bedi & Toshniwa (2018) exponen un modo empírico de descomposición basado en aprendizaje profundo para estimar la demanda de electricidad. Para demostrar la aplicabilidad de la propuesta, son empleados a los datos de consumo de electricidad en la ciudad de Chandigarh.

Algunos investigadores se fundamentan en establecer un modelo mediante las técnicas de aprendizaje profundo y minería de datos, que permita estimar la carga y además, aprovechan las bondades de sus resultados para analizar y predecir el comportamiento del precio de la electricidad (Lebotsa *et al.*, 2018; Ping & Chiou, 2018; Zahid *et al.*, 2019).

En Cuba, varios trabajos son presentados en los que el análisis de la demanda juega un papel fundamental (Hernández, Herrera, Vilaragut & Sousa, 2021; Peña, Viego, Gómez & Padrón, 2019). Por otro lado, la investigación presentada por Carrillo, Somoza & Boudet (2017), sienta sus bases en la determinación de los valores de eficiencia en el uso de la electricidad en cada provincia, donde relaciona la variación climática sobre la demanda eléctrica en el sector residencial. Esto obligaría a la división de las mediciones según la época del año. Pudiera plantearse una relación con alguna otra condición con un comportamiento no tan errático como las condiciones climatológicas, como la cantidad de clientes presentes en el circuito en cuestión.

En este trabajo se propone realizar una modelación matemática y una modelación mediante redes neuronales para determinar la demanda máxima en función de la cantidad de clientes en circuitos de distribución primaria de la provincia Holguín, para ser aplicada a circuitos en localidades donde, entre otras circunstancias, las condiciones económicas no permitan la colocación de equipos de mediciones o el acceso a la información resulte limitado. El primer tipo de modelación se realiza haciendo uso de la herramienta *Cuervexpert* 1.3, mientras que la red neuronal que mejor se ajuste a los datos se obtiene mediante el *software* Matlab R2018b, a través del código nntool.

Materiales y métodos

Para la modelación se consideran las mediciones tomadas del Sistema de Gestión de Redes (SIGERE), la cual recoge información general de los circuitos eléctricos del país, entre ellos, la demanda diaria.

Los datos tomados pertenecen a las redes de distribución primaria de la provincia de Holguín para el año 2019, de los cuales fueron considerado 139 de los 141 presentan en el municipio.

Modelación matemática

La modelación matemática se lleva a cabo mediante la herramienta *Curvaexpert 1.3*. Este programa presenta una familia de curvas, permite, mediante la introducción de una variable dependiente y una independiente, en este caso, la demanda máxima y el número de clientes, respectivamente, establecer la ecuación, con su correspondiente curva, que mejor se ajuste a los datos introducidos. La selección automática del programa se basa en el coeficiente de correlación entre las variables involucradas y el error estándar con mejores resultados.

El modelo también puede seleccionarse manualmente, o sea, el software determina todas las familias de curvas que posee y, en base al criterio del investigador o usuario, escoge la mejor variante.

Modelación mediante redes neuronales

Una de las herramientas de la inteligencia artificial son las redes neuronales. Estas redes están compuestas por elementos matemáticos, denominados neuronas, que han sido inspirados y en cierta medida, tratan de imitar la actividad funcional del sistema nervioso central humano. Tal y como ocurre en la naturaleza, el funcionamiento adecuado de estos elementos depende de la calidad de su interconexión y de la función de activación del mecanismo.

Dado que la salida total está determinada por la evaluación de la función de transferencia f , la respuesta de la red depende de la naturaleza de ésta. Así, la función de transferencia se escoge en dependencia del problema que la neurona trata de resolver.

Si la salida digitalizada presenta un comportamiento no lineal y la salida es positiva, como en el caso de estudio, la función transferencia pudiera ser logsig (ecuación 1).

$$f(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

La salida generalmente la constituye una función transferencia pureline. La de ecuación de la misma está dada por (2), que representa una línea recta que pasa por el origen con una pendiente de 450, donde son iguales los valores de entrada y salida.

$$y = x \quad (2)$$

Para la implementación de la red que mejor se ajuste a los datos se emplea el software Matlab R2018b. El mismo posee una opción para programar la red neuronal y una opción de interfaz gráfico, siendo esta última la utilizada en el estudio, a través del toolbox nntool.

La selección de la red neuronal que mejor se ajuste a las variables involucradas en la modelación, se realiza mediante la comparación de los coeficientes de correlación resultantes y el error medio cuadrático. El método empleado es el de ensayo y error, donde se escogen las configuraciones con mejores resultados.

Resultados y discusión

La relación cantidad de clientes y demanda máxima de cada circuito se muestra en la figura 1. Obsérvese que existen algunas cargas con un comportamiento un poco alejado de la lógica, sin embargo, en su mayoría presentan una distribución más o menos uniforme.

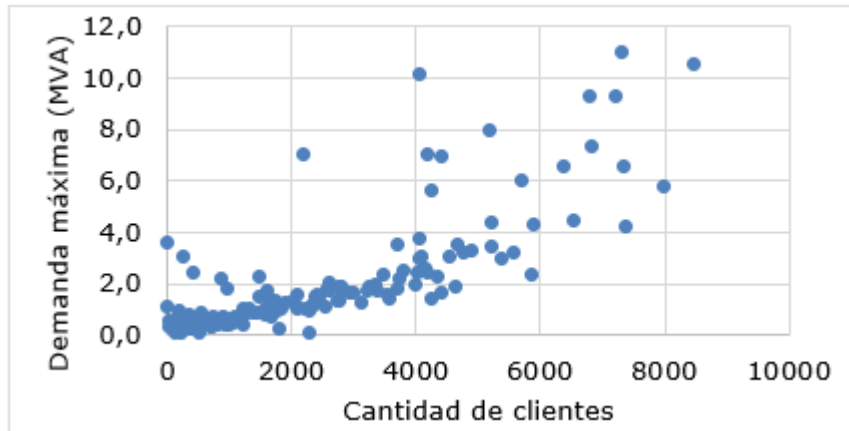


Figura 1. Relación cantidad de clientes y demanda máxima.

La mayoría de los puntos se encuentran ubicados hasta la cantidad de 6000 clientes, para un 95 % de los casos, aproximadamente, como se describe en la figura 2.

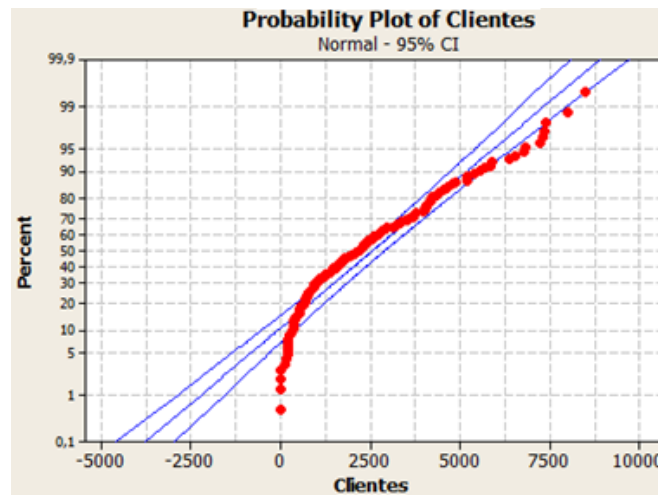


Figura 2. Distribución de probabilidad de la cantidad de clientes.

El considerar un número mayor de clientes pudiera incidir en la exactitud del modelo, sin embargo, se tienen en cuenta toda la información disponible, ya que se pretende el modelo sea aplicable para todos los circuitos de distribución existentes.

Resultados del modelo matemático

La herramienta de cálculo empleada ofrece un grupo de resultados, sobre los cuales se elige la mejor variante. En la tabla 1 se muestran estos efectos para los cuatro modelos con mejores resultados.

Tabla 1. Resultados de los cuatro mejores modelos

Modelos	Error estándar	Coefficiente de correlación
Modelo Gaussiano	1,348	0,811
Modelo modificado de Hoerl	1,356	0,809
Modelo con base polinómica	1,311	0,833
Modelo con base cuadrática	1,346	0,812

Queda demostrado que el modelo con base polinómica presenta un coeficiente de correlación más elevado que el resto. Asimismo, el error estándar es inferior al resto, por lo que la variante que mejor se adapta a los datos involucrados es este, el cual presenta grado nueve; valor escogido previamente por el usuario.

El modelo queda caracterizado por la ecuación.

$$\begin{aligned}
 p(x) = & 1.25395 + (-0.0015487742x) + \\
 & (-2.4416055e^{-6}x^2) + 8.6695498e^{-9}x^3 + \\
 & (-7.9577435e^{-12}x^4) + 3.5374679e^{-15}x^5 + \\
 & (-8.638542e^{-19}x^6) + 1.1824858e^{-22}x^7 + \\
 & (-8.5044133e^{-27}x^8) + 2.5005938e^{-31}x^9
 \end{aligned}
 \tag{3}$$

La curva característica para este modelo queda representada por la mostrada en la figura 3, donde las variables en el eje de las abscisas representan la cantidad de clientes, mientras que el eje de las ordenadas constituye la demanda máxima.

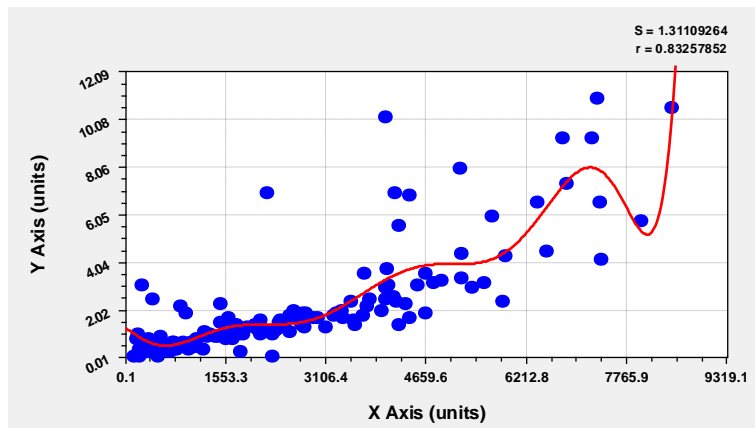


Figura 3. Curva característica del modelo polinómico.

Resultados del modelo mediante redes neuronales

El trabajo con las redes neuronales, en este caso, se realiza mediante el ensayo y error, buscando obtener los mejores resultados. En la figura 4 aparece representado los resultados del error medio cuadrático para un grupo de pruebas, donde se obtuvieron los mejores efectos.

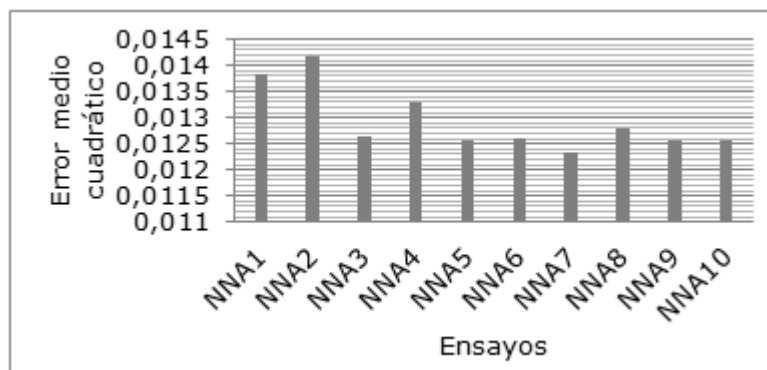


Figura 4. Distribución del error medio cuadrático para 10 ensayos.

De la figura 4 se deduce que el ensayo NNA7 se ofrece mejores resultados en cuanto al error medio cuadrático obtenido con un valor de $1.23 \cdot 10^{-3}$.

Por otro lado, los coeficientes de correlación para estos mismos ensayos se describen en la tabla 2.

Tabla 2. Coeficiente de correlación obtenido en los 10 mejores ensayos

Pruebas	Coeficiente de correlación
NNA1	0,82128
NNA2	0,82347
NNA3	0,81852
NNA4	0,84066
NNA5	0,84079
NNA6	0,84178
NNA7	0,84048
NNA8	0,84389
NNA9	0,8379
NNA10	0,8412

Obsérvese cómo existen otras configuraciones de redes neuronales en los que se obtienen coeficientes de correlación superiores al ensayo NNA7. Sin embargo, la diferencia pudiera no ser tan significativa, y en base a que presenta el menor error medio cuadrático, se toma este como el mejor modelo de red.

La red escogida presenta una configuración de 10 neuronas en la primera y segunda capa oculta, ambas con función logsig. La capa de salida está constituida con una neurona con función transferencia pureline. En la figura 5 se muestra la estructura de la red neuronal que mejor se ajusta a los datos.




Figura 5. Estructura de la prueba NNA7.

Los resultados de los coeficientes de correlación para el ajuste de la red se muestran en la figura 6. Se muestran los resultados obtenidos en el entrenamiento, la validación y la prueba, así como la relación para todas las variables involucradas en el estudio.

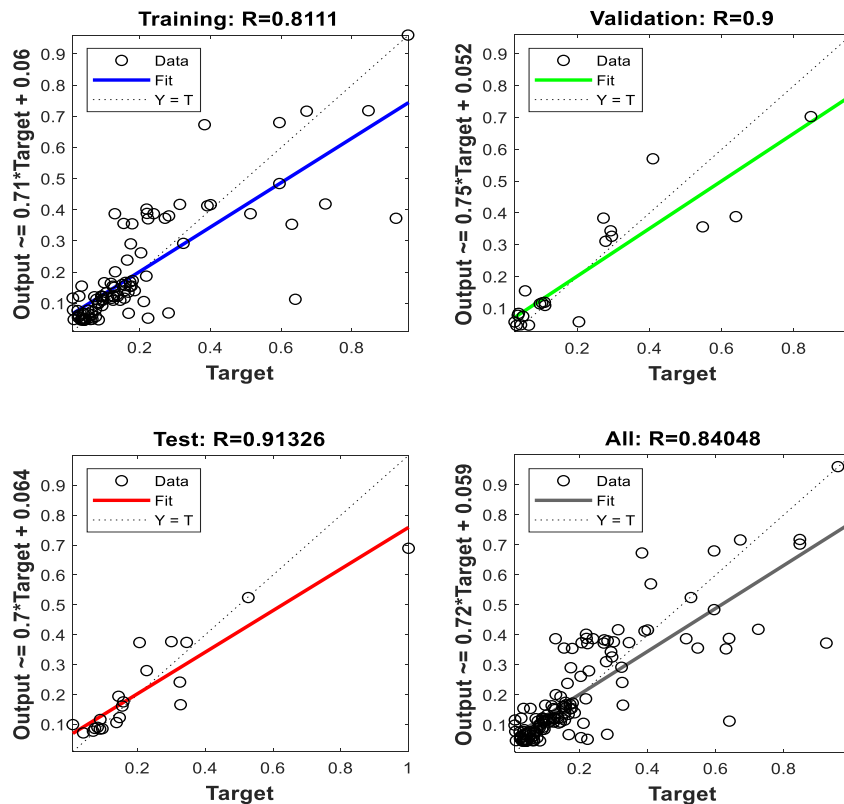


Figura 6. Coeficiente de correlación entre la variable de salida y la variable de entrada obtenido en el ensayo NNA7.

La distribución del error medio cuadrático en función de las épocas para el proceso de entrenamiento, la validación y la prueba aparece representada en la figura 7.




Figura 7. Comportamiento del error medio cuadrático en los procesos de entrenamiento, validación y prueba de la red neuronal artificial.

Conclusiones

La relación demanda máxima contra cantidad de clientes queda modelada tanto matemáticamente, como a través de una red neuronal artificial con resultados satisfactorios.

En la modelación matemática se obtuvieron los mejores resultados con los modelos gaussiano, modelo modificado de Hoerl, polinómico y cuadrático; destacándose el polinómico por presentar el menor error estándar, con un valor de 1,311. Asimismo, el coeficiente de correlación entre las variables involucradas en base a los efectos de este, resulta de 0,833.

La red neuronal artificial con mejores resultados presenta una neurona en la primera y segunda capa oculta, ambas con función logsig, mientras que la capa de salida está constituida por una neurona con función transferencia pureline. El error medio cuadrático obtenido con por la misma equivale a $1,23 \cdot 10^{-3}$ con un coeficiente de correlación de 0,840 entre las variables de entrada y salida, aproximadamente.

Ambos modelos obtenidos evidencian buenos resultados en la modelación de la característica demanda máxima contra cantidad de clientes, permitiendo de este modo

establecer una relación entre ambas variables y ser aplicada a circuitos en localidades donde, entre otras circunstancias, las condiciones económicas no permitan la colocación de equipos de mediciones o existan limitaciones en cuanto al acceso a la información.

Referencias bibliográficas

- AL-MUSAYLH, M. S.; DEO, R. C.; ADAMOWSKI, J. F. & LI, Y. 2018. Short-term electricity demand forecasting with MARS, SVR and ARIMA models using aggregated demand data in Queensland, Australia. *Advanced Engineering Informatics* 35: 1-16. doi: <https://doi.org/10.1016/j.aei.2017.11.002>.
- BEDI, J. & TOSHNIWA, D. 2018. Empirical Mode Decomposition Based Deep Learning for Electricity Demand Forecasting. *IEEE Acces* 6: 49144-49156. doi: <http://10.1109/ACCESS.2018.2867681>.
- BEDI, J. & TOSHNIWAL, D. 2019. Deep learning framework to forecast electricity demand. *Applied Energy* 238: 1312-1326. doi: <https://doi.org/10.1016/j.apenergy.2019.01.113>.
- CARRILLO, E. R. V.; SOMOZA, J. C. & BOUDET, D. R. 2017. Potencial de mitigación de dióxido de carbono en el consumo de electricidad del sector residencial en Cuba. *Revista Cubana de Meteorología* 23(3): 341-348.
- CASTRO, C. M.; SEVERIANO, R. S. & SPERANDIO, M. 2019. *Sensitivity Analysis of the Brazilian Methodology of Calculation of Technical Losses in the Electric Energy Distribution System*. Paper presented at the 2019 IEEE PES Innovative Smart Grid Technologies Conferences-Latin America (ISGT Latin America), Gramado, Brazil.
- DARMANIS, M.; ÇAKAN, M.; MOUSTRIS, K. P.; KAVADIAS, K. A. & NIKAS, K. P. 2020. Utilisation of Mass and Night Ventilation in Decreasing Cooling Load Demand. *Sustainability* 12(18): 7826.
- FENG, Z.; NIU, W.; WANG, W.; ZHOU, J. & CHENG, C. 2019. A mixed integer linear programming model for unit commitment of thermal plants with peak shaving operation aspect in regional power grid lack of flexible hydropower energy. *Energy* 175: 618-629. doi: <https://doi.org/10.1016/j.energy.2019.03.117>.

- GALARZA, J.; CONDEZO, D.; SAENZ, B. & HUARAC, D. 2021. Evaluación de la red de distribución: conexión del vehículo eléctrico híbrido enchufable. *Revista Tecnología en Marcha* 34(4): 50-62. doi: <http://10.18845/tm.v34i4.5384>.
- GHADAMI, N.; GHEIBI, M.; KIAN, Z., FARAMARZ, M. G.; NAGHEDI, R., EFTEKHARI, M. ; ... & TIAN, G. 2021. Implementation of solar energy in smart cities using an integration of artificial neural network, photovoltaic system and classical Delphi methods. *Sustainable Cities and Society* 74: 103149. doi: <https://doi.org/10.1016/j.scs.2021.103149>.
- HERNÁNDEZ, D. A.; HERRERA, F. M. V.; VILARAGUT, M. L. & SOUSA, V. S. 2021. Modelado y simulación de una microrred autónoma. *Ingeniería Energética* 42(2): 36-47.
- HUNG, Y. C. & MICHAELIDIS, G. 2019. Modeling and Optimization of Time-of-Use Electricity Pricing Systems. *IEEE Transactions on Smart Grid* 10(4): 4116-4127. doi: 10.1109/TSG.2018.2850326.
- JANG, Y.; BYON, E.; JAHANI, E. & CETIN, K. 2020. On the long-term density prediction of peak electricity load with demand side management in buildings. *Energy and BUILDINGS* 228: 110450. DOI: [HTTPS://DOI.ORG/10.1016/J.ENBUILD.2020.110450](https://doi.org/10.1016/j.enbuild.2020.110450).
- KAVADIAS, K. A.; APOSTOLOU, D. & KALDELLIS, J. K. 2018. Modelling and optimisation of a hydrogen-based energy storage system in an autonomous electrical network. *Applied Energy* 227: 574-586. doi: <https://doi.org/10.1016/j.apenergy.2017.08.050>.
- KIM, T. Y. & CHO, S. B. 2019. Predicting residential energy consumption using CNN-LSTM neural networks. *Energy* 182: 72-81. doi: <https://doi.org/10.1016/j.energy.2019.05.230>.
- LEBOTSA, M. E.; SIGAUKE, C.; BERE, A.; FILDERS, R. & BOYLAN, J. E. 2018. Short term electricity demand forecasting using partially linear additive quantile regression with an application to the unit commitment problem. *Applied Energy* 222: 104-118. doi: <https://doi.org/10.1016/j.apenergy.2018.03.155>.

- LI, R.; WEI, W.; MEI, S.; HU, Q. & WU, Q. 2019. Participation of an Energy Hub in Electricity and Heat Distribution Markets: An MPEC Approach. *IEEE Transactions on Smart Grid* 10(4): 3641-3653. doi: 10.1109/TSG.2018.2833279
- LU, R. & HONG, S. H. 2019. Incentive-based demand response for smart grid with reinforcement learning and deep neural network. *Applied Energy*, 236, 937-949. doi: <https://doi.org/10.1016/j.apenergy.2018.12.061>.
- MORADI, M.; NAZARI, M.; MOHAMMADI, B.; GALAVANI, S. & RABIEE, A. 2020. A Two-Stage Mathematical Programming Approach for the Solution of Combined Heat and Power Economic Dispatch. *IEEE Systems Journal* 14(2), 2873-2881. doi: 10.1109/JSYST.2019.2958179.
- MURALITHARAN, K.; SAKTHIVEL, R. & VISHNUVARTHAN, R. 2018. Neural network based optimization approach for energy demand prediction in smart grid. *Neurocomputing* 273: 199-208. doi: <https://doi.org/10.1016/j.neucom.2017.08.017>.
- PEÑA, J. A.; VIEGO, R. F.; GÓMEZ, R. S. & PADRÓN, E. P. 2019. Pronóstico del Consumo Pico para la Gestión Energética de la Universidad de Cienfuegos. *Universidad y Sociedad* 11(4): 220-228.
- PING, H. K., & CHIOU, J. H. 2018. An Electricity Price Forecasting Model by Hybrid Structured Deep Neural Networks. *Sustainability* 10(1280): 1-17. doi: <http://dx.doi.org/10.3390/su10041280>.
- POPOV, V.; PRYKHNO, V. & PRYKHNO, D. 2019. Development of the Method of Determining the Power and Electricity Losses in Distribution Network of Shop Electrical Supply. In *2019 IEEE 6th International Conference on Energy Smart Systems (ESS)* 104-107. IEEE.
- RUNGE, J. & ZMEUREANU, R. 2019. Forecasting Energy Use in Buildings Using Artificial Neural Networks: A Review. *Energies* 12(3254): 1-27. doi: <http://dx.doi.org/10.3390/en12173254>.
- SHIRZADI, N.; NIZAMI, A.; KHAZEN, M. & NIK-BAKHT, M. 2021. Medium-Term Regional Electricity Load Forecasting through Machine Learning and Deep Learning. *Designs* 5(2): 27.

- SIGAUKE, C., & NEMUKULA, M. M. 2020. Modelling extreme peak electricity demand during a heatwave period: a case study. *Energy Systems* 11(1), 139-161. doi: 10.1007/s12667-018-0311-y
- ZAHID, M.; AHMED, F.; JAVAID, N.; ABID, R. A.; ZAINAB, H. S. K., JAVAID, A., . . . ILAHI, M. 2019. Electricity Price and Load Forecasting using Enhanced Convolutional Neural Network and Enhanced Support Vector Regression in Smart Grids. *Electronics* 8(2): 122 doi: <http://dx.doi.org/10.3390/electronics8020122>.
- ZHANG, S.; CHENG, H.; WANG, D.; ZHANG, L.; LI, F. & YAO, L. 2018. Distributed generation planning in active distribution network considering demand side management and network reconfiguration. *Applied Energy* 228: 1921-1936. doi: <https://doi.org/10.1016/j.apenergy.2018.07.054>.