

Definición de una red neuronal para simular el consumo eléctrico horario de la Ciudad de Salta

Franco Zanek^{1,2}, Eduardo Xamena¹, Diego Rodríguez¹

¹ Departamento de Informática, Facultad de Ciencias Exactas, Universidad Nacional de Salta

fzanek@di.unsa.edu.ar

² Instituto de Investigación en Energías no Convencionales (INENCO) – CONICET - Universidad Nacional de Salta

Resumen. Los pronósticos de demanda de electricidad son extremadamente importantes para los proveedores de energía y otros participantes en la generación, transmisión, distribución y mercados de energía eléctrica. Los modelos precisos para el pronóstico de carga de energía eléctrica son esenciales para la operación y planificación de una ciudad, localidad o región de interés. Además de desempeñar un papel muy importante en el campo de la programación, análisis de contingencia, análisis de flujo de carga, planificación y mantenimiento del sistema eléctrico. Es por eso que en este artículo se presenta un modelo basado en redes neuronales artificiales (ANN) con el fin de poder predecir la demanda eléctrica horaria, discriminada por mes. Si bien en la literatura existen modelos que ayudan a resolver el problema, al aplicarlo para esta situación se presentaron demasiadas divergencias entre los valores arrojados y los valores reales. Este estudio se lleva a cabo a partir de los datos, para Salta Capital en la provincia de Salta. Los resultados así obtenidos fueron comparados con valores de consumo reales para medir la eficiencia de los modelos definidos.

Palabras clave: Red Neuronal Artificial, Curva de carga eléctrica, Predicción horaria.

1 Introducción

Desde principios de la década de 1990, el proceso de desregulación y la introducción de mercados competitivos han estado remodelando el panorama de los sectores de energía tradicionalmente monopólicos y controlados por el gobierno. En muchos países del mundo, la electricidad se comercializa ahora según las reglas del mercado mediante contratos al contado y de derivados. Sin embargo, la electricidad es un bien muy especial, ya que es económicamente no almacenable y la estabilidad del sistema eléctrico requiere un equilibrio constante entre la producción y el consumo. Al mismo tiempo, la demanda de electricidad depende de variables climáticas (temperatura, velocidad del viento, precipitación, etc.) y de la intensidad de las actividades comerciales y cotidianas (en horas pico frente a horas no pico, días laborables frente a fines de semana, días festivos y próximos días festivos, entre otros). Por un lado, estas características únicas y específicas conducen a dinámicas de consumo no observadas en ningún otro mercado, exhibiendo estacionalidad en los niveles diario, semanal y anual, y

picos de consumos abruptos, de corta duración y generalmente imprevistos. Por otro lado, han animado a los investigadores a intensificar sus esfuerzos en el desarrollo de mejores técnicas de predicción.

A nivel empresarial, las previsiones de carga de la electricidad se han convertido en un insumo fundamental para los mecanismos de toma de decisiones de las empresas de energía. Se han probado una variedad de métodos e ideas para la previsión de la demanda de la electricidad, con diversos grados de éxito. Se han utilizado para ellos diversos modelos, basados en análisis de tendencias y modelos basados en inteligencia artificial, entre los grupos más grandes que se puede mencionar.

En la literatura, varios investigadores presentaron diversos modelos para el pronóstico del consumo eléctrico. Los análisis de series temporales como ARIMA, modelos estadísticos y otros métodos numéricos como algoritmos genéticos, optimización de enjambres de partículas, redes neuronales artificiales y máquinas de vectores, fueron utilizados como medios para poder pronosticar el consumo eléctrico [1]. Taylor, en su trabajo, utilizó métodos estadísticos de pronóstico para el pronóstico de la demanda de electricidad a corto plazo. Para adaptarse al ciclo estacional a lo largo del año, aplicó tres métodos de pronóstico de doble temporada basándose en datos de 6 años de Francia y Gran Bretaña [2]. Fan y Hyndman propusieron "modelos semi-paramétricos" para pronosticar la relación entre la demanda eléctrica y las variables de entrada como fecha del calendario, la demanda real retrasada y la temperatura histórica y promedio. Sus métodos se aplicaron al Mercado Nacional de Electricidad de Australia para pronosticar la demanda de electricidad cada media hora durante un máximo de una semana [3]. Teniendo en cuenta los días festivos y los fines de semana, Hyndman y Fan calcularon las distribuciones de probabilidad exactas de los valores futuros de la posible demanda [4].

Por otro lado, se han propuesto varios tipos de modelos de predicción de energía basados en redes neuronales. Chang et al. [5] propusieron una red neuronal de retro-propagación para la predicción del consumo de electricidad en todo el país utilizando un pequeño conjunto de datos. La red neuronal propuesta consta de una capa oculta, mientras que hay dos neuronas en la capa oculta. Luo et al. [6] desarrollaron un modelo de predicción basado en redes neuronales feed-forward para cargas de refrigeración y calefacción en edificios. Las entradas al modelo de predicción incluyeron múltiples lecturas de sensores de temperatura en tiempo real, perfil de datos meteorológicos pronosticados y datos históricos de consumo de energía. Se probaron y seleccionaron diferentes números de neuronas para varias sub-zonas. Posteriormente, Luo et al. [7] desarrolló un modelo de predicción de redes neuronales feed-forward mejoradas por agrupamiento para generar demanda de refrigeración. Se adoptaron varios sub-modelos basados en redes neuronales para la predicción durante todo el año, mientras que un proceso de prueba y error determina la cantidad de neuronas en cada sub-modelo. Luo et al. [8] también desarrolló un algoritmo genético híbrido (GA) y un modelo de predicción basado en redes neuronales feed-forward, en el que se adoptó GA para elegir la arquitectura de red óptima. Los conjuntos de datos de entrada al modelo de predicción se componen de datos meteorológicos históricos y firmas de tiempo, mientras que no se consideró el perfil histórico de consumo de energía.

Siguiendo la misma línea, los autores [9-13] desarrollan modelos basados en redes neuronales para la predicción de la demanda eléctrica en el mediano plazo. Para estos modelos, se tuvieron en cuenta diversas localizaciones geográficas del mundo y para estos casos, las variables de entrada fueron similares para los modelos descritos en el párrafo anterior, sin embargo para estos modelos el valor del Error Cuadrático Medio ronda el 7%. Como así también, los autores [14,15] desarrollan modelos para la predicción a largo plazo, de la demanda eléctrica. En estos casos, además de las variables descriptas anteriormente, se tuvieron en cuenta variables como tamaño de la población, producto bruto interno. Para estos casos el error cuadrático medio ronda el 4.6%.

En los trabajos más vigentes sobre la problemática bajo estudio, se destacan los desarrollos de trabajos basados en redes neuronales long short-term memory (LSTM). Wang et al. [16] adoptó la red neuronal LSTM para la predicción del consumo de energía a largo plazo de un sistema de refrigeración. Se encontró que el método LSTM propuesto dio como resultado un error cuadrático medio 19,7% más bajo que la red neuronal de realimentación de referencia. Khafaf et al. [17] propusieron un modelo de red de neuronas LSTM para pronosticar un consumo de energía de 3 días por delante de grupos de usuarios de energía. Wang et al. [18] adoptaron una red neuronal LSTM para la predicción del consumo de energía y la detección de anomalías en la red. Khan et al. [19] adoptaron un modelo de red neuronal convolucional híbrida con autocodificador LSTM para la predicción del consumo de energía en edificios residenciales y comerciales. Wei et al. [20] propusieron un análisis de espectro singular híbrido y un modelo LSTM para la predicción del consumo diario de gas natural. Singaravel et al. [21] probó el rendimiento de LSTM para el consumo de energía del edificio en la etapa de diseño. Se evaluaron 201 casos de diseño con cuatro configuraciones diferentes del modelo LSTM. Se encuentra que los modelos LSTM tienen mayor precisión y mayor velocidad de cálculo que los modelos ANN. Zhou et al. [22] propusieron un modelo LSTM para predecir el consumo de energía de los sistemas de aire acondicionado. Se realizó una experimentación constante para encontrar los mejores hiperparámetros, incluida la cantidad de pasos de entrenamiento, la duración de la serie temporal que ingresa al LSTM y la tasa de aprendizaje.

A partir de la revisión de la literatura, se propone modelar la realidad del consumo eléctrico de la Ciudad de Salta mediante Redes Neuronales Artificiales Feed Forward con Backpropagation como política de aprendizaje supervisado. La predicción del consumo eléctrico a escala de ciudad tiene amplias aplicaciones, y encontramos muchos estudios sobre este tema. Sin embargo, una importante brecha de investigación que identificamos después de revisar los estudios existentes es que si bien se plantearon diferentes enfoques, ninguno proporciona los datos, el modelo o el código de fuente para revisarlo o reutilizarlo.

Como consecuencia de lo expuesto anteriormente, es necesario desarrollar y plantear modelos que representen la realidad de la Ciudad de Salta y permitan, mediante el uso de la red mencionada anteriormente, poder brindar una solución al problema.

Para cumplir con este objetivo, es necesario entender la situación eléctrica del país durante el período bajo estudio. Para posteriormente poder describir los modelos ob-

tenidos y en concluir el trabajo con el análisis de resultados, conclusiones y planteo de líneas de investigación futuras.

2 Mercado Eléctrico Argentino

En esta sección se presentan las características del mercado eléctrico argentino actual. Se utilizan los reportes realizados por Ministerio de Minería y Energía de la Nación y Compañía Administradora del Mercado Mayorista Eléctrico (CAMMESA), del año 2019.

Argentina ha registrado en los últimos años un incremento de situaciones de stress y exigencia de los sistemas de distribución de energía eléctrica, afectando así el funcionamiento y configuración del sistema eléctrico en su conjunto. Se observa un aumento de la estacionalidad de la demanda con picos de energía y potencia que se desarrollan típicamente en verano y en invierno. Con el paso de los años se puede apreciar el crecimiento tendencial de la demanda. Esto se puede deber al aumento de equipos de acondicionadores de aire y de calefacción eléctrica, dada la ausencia de mecanismos de incentivos por tarifas y políticas de eficiencia energéticas adecuadas. Estos picos provocan un alto costo de mantenimiento del sistema por la necesidad de mayor potencia y de las líneas de transporte y distribución que deben estar disponibles para ser utilizadas en esos periodos, que implica mayores inversiones con un bajo factor de utilización [23].

La demanda total puede dividirse en dos grandes grupos: residencial y no residenciales. Dentro de la demanda no residencial a su vez se encuentran 5 subcategorías dependiendo de la metodología de facturación y del volumen de su demanda de energía y potencia: comerciales y Grandes Usuarios de Distribuidoras (GUDIs), Grandes Usuarios Particulares (GUPAs), Grandes Usuarios Menores (GUMEs) y Grandes Usuarios Mayores (GUMAs). Dentro de las 5 subcategorías no residenciales, sólo los GUMA's tienen relación directa con CAMMESA comprando energía en el Mercado Mayorista, el resto compran la energía (y algunos contratan potencia) a través de las distribuidoras [23]. En las figuras 1-4, se realiza una comparación del consumo eléctrico mensual de las diferentes regiones del país.

Podemos observar que la región que mayor demanda eléctrica posee, es la del Gran Buenos Aires. Esto se debe, por una parte, a la mayor densidad demográfica que posee la región en relación con las otras regiones del país y por otro, las tarifas eléctricas, durante el período de estudio, fueron las más baratas del país, lo que incentivó a los ciudadanos a comprar más artefactos eléctricos, produciendo una mayor demanda. Además, puede notarse que las regiones Comahue y Patagónica, son las regiones que menor demanda eléctrica posee y esto se debe por los motivos opuestos al caso anterior; son las zonas geográficas donde se encuentra la menor densidad demográfica del país y donde las tarifas eléctricas son las más caras, por lo que el uso de la electricidad es menor. Además estas regiones no cuentan con demasiado desarrollo comercial e industrial, por motivos diversos, destacándose entre ellos la geografía del lugar, las

largas distancias entre las distintas localidades, la poca inversión por parte de los gobiernos para el desarrollo y la explotación de dichos lugares, entre otros factores similares.

3 Metodología de Trabajo

Como se mencionó anteriormente, en este trabajo se propone modelar la realidad del consumo eléctrico horario discriminado por mes, para la Ciudad de Salta mediante Redes Neuronales Artificiales Feed Forward con Backpropagation como política de aprendizaje supervisado. En la figura XXX se puede ver reflejado el flujo del proceso llevado a cabo.




Fig. 1. Metodología de trabajo propuesta

3.1 Variables involucradas y datos utilizados

Dado que el objetivo que se persigue con este trabajo es poder estimar el consumo eléctrico horario, las variables más adecuadas y que están correlacionadas directa o indirectamente con la cantidad de Kwh consumida por una ciudad en una hora, queda determinada por factores como:

1. Datos referidos al día y hora bajo estudio. Los días están considerados como días julianos y no días calendario.
2. Datos Climáticos (Temperatura y humedad)

Estas variables influyen directamente en el consumo eléctrico, ya que dentro del primer grupo consideramos los días del año, que no es lo mismo considerar un día festivo, que un día laboral o un fin de semana. Mientras que para la variable relacionada a la hora del día sucede lo mismo, no es lo mismo considerar el consumo en horarios nocturnos que diurnos. Por otro lado, el segundo grupo de variables afectan el consumo en relación al uso de artefactos de refrigeración o calefacción al exponer a la gente a temperaturas fuera de su zona de confort térmico.

Por otro lado, variables como el valor de la tarifa eléctrica, o el tamaño de la población, no tienen una influencia en el modelado del consumo eléctrico horario, ya que son variables que se mantienen constantes de una hora a la otra. Por lo tanto, las entradas al modelo planteado, son cuatro y corresponden con los datos climáticos (temperatura y humedad), datos relacionados al día y a la hora que se pretende pronosticar.

Al ya tener las variables definidas, es necesario contar con los datos que van a permitir el posterior entrenamiento y validación de los modelos. Para ello se fija como período de trabajo los años 2016 a 2019 y las fuentes de los datos son las siguientes:

- Datos de Consumo histórico: Compañía Administradora del mercado Mayorista Eléctrico (CAMMESA).
- Datos Climáticos: Instituto Nacional de Tecnologías Agropecuarias (INTA).

3.2 Pre-Procesamiento de los datos

A partir de este análisis, podemos concluir que es necesario un proceso de estandarización y normalización de los datos, ya que de esta manera todas las variables tendrán un peso similar a la hora de trabajar en la red; sino procedemos con este proceso de normalización, puede ocurrir que algunas variables como el día (que posee valores más altos) jueguen un peso más importante frente a las otras variables.

Para poder determinar qué proceso debemos seguir, necesitamos determinar que distribución sigue cada uno de los datos y mediante las técnicas de validación estadísticas (chi-cuadrado).

Para las variables que modelan la hora y el día bajo estudio, se observó que las mismas distribuyen uniforme, por lo que se aplica el proceso de estandarización de dicha distribución considerando como valores mínimo y máximo al primer y último día de cada mes, expresados en días julianos, esto es para la variable que modela los días. Mientras que para la variable que modela las horas, el valor mínimo y máximo corresponde a la primera y última hora de cada día, respectivamente.

Mientras que las demás variables distribuyen normal y para poder estandarizar, se utiliza el proceso de estandarización de dicha distribución.




Fig. 2. Distribución del consumo eléctrico mensual, para cada una de las regiones. Para el período enero-diciembre 2019




Fig. 3. Distribución del consumo eléctrico mensual, para cada una de las regiones. Para el período enero-diciembre 2018




Fig. 4. Distribución del consumo eléctrico mensual, para cada una de las regiones. Para el período enero-diciembre 2017

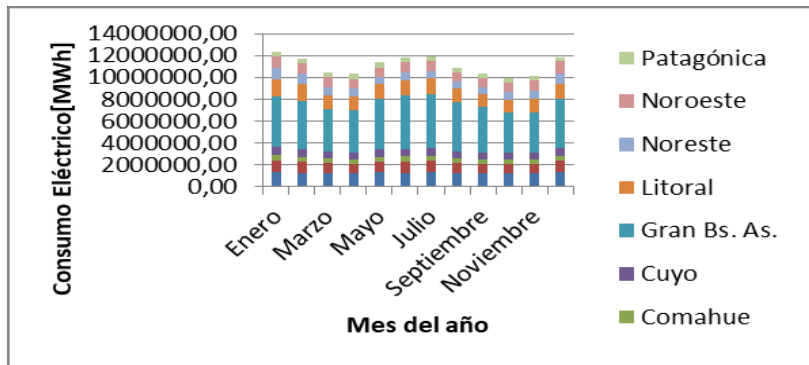


Fig. 5. Distribución del consumo eléctrico mensual, para cada una de las regiones. Para el período enero-diciembre 2016

3.3 Definición de las estructuras de red

Determinar el número adecuado de neuronas ocultas, para evitar el ajuste excesivo, es fundamental para el problema. Uno de los principales desafíos en el diseño de redes neuronales es la determinación de neuronas ocultas con un error mínimo y la mayor precisión, es probable que el conjunto de entrenamiento y el error de generalización sean altos antes de que comience el aprendizaje. Sin embargo, durante el entrenamiento, la red se adapta para disminuir el error en los patrones de entrenamiento, de esta manera, la precisión del entrenamiento está determinada por los parámetros bajo consideración.

El estudio del número capas y neuronas ocultas, se realiza para cada uno de los meses del año, por lo que se obtienen doce sub-modelos de redes neuronales (uno por cada mes del año), que conforman el modelo de red neuronal para solucionar el problema bajo estudio.

La selección de los modelos óptimos para cada mes se realiza siguiendo dos heurísticas (Algoritmo Genético y Colonia de Abejas) desarrollados por el autor. En la tabla que se detalla a continuación, se detallan los modelos adoptados para cada uno de los meses del año. En la segunda columna, se detalla la arquitectura adoptada para el mes, solo se tienen en cuenta las capas ocultas, ya que para todos los meses la capa de entrada como de salida son exactamente las mismas. La capa de entrada cuenta con 4 neuronas que representa los variables que se describió anteriormente; mientras que, la capa de salida cuenta con una sola neurona que representa la estimación del consumo eléctrico. Además, en la tabla 1, en la columna se puede observar los errores obtenidos para cada uno de los modelos en las etapas de entrenamiento y validación.

Como se mencionó anteriormente, el total de datos obtenidos fueron de 12000 por mes (considerando los 4 años bajo estudio). De los cuales el 20% correspondía a datos utilizados para obtener los modelos óptimos mensuales y posteriormente fueron utilizados en la etapa de validación. El resto, correspondes a valores que fueron utilizados para la etapa de entrenamiento. Además, para la etapa de validación se optó por utilizar la estrategia de cross-validation. La separación de los datos fue realizada teniendo en cuenta los distintos perfiles climáticos y sociales que se presentan a lo largo de cada mes.

Tabla 1. Modelos obtenidos para cada mes

Mes	Arquitectura Adoptada	MAPE Entrenamiento	MAPE Validación
Enero	4-5-1	4.67 %	3.98%
Febrero	4-8-1	4.6 %	2.8%
Marzo	4-5-1	4.46%	2.75%
Abril	4-8-1	3.72%	3.89%
Mayo	4-8-1	2.05%	1.24%
Junio	4-5-1	3.78%	2.56%
Julio	4-17-1	2.45%	3.09%
Agosto	4-8-1	4.32%	4.09%
Septiembre	4-8-1	3.4%	3%
Octubre	4-5-1	2.43%	1.4%
Noviembre	4-17-1	3.56%	2.34%
Diciembre	4-5-1	4.05%	4.34%

Los parámetros utilizados para el proceso fueron:

- Función de Pérdida: se tuvo en cuenta el error cuadrático medio.
- Optimizador: Se utilizó la técnica SGD con tasa de aprendizaje de 0.1.
- Epochs: 1000

Para las capas ocultas, la función de activación adoptada fue la función exponencial.

4 Análisis de Resultados

La evaluación del rendimiento predictivo de los diferentes modelos desarrollados se realizó mediante la comparación con el conjunto de datos históricos. Para estudiar el desempeño de los modelos mencionados, se utilizó el error porcentual absoluto (MAPE). Las estructuras óptimas para cada mes del año se plantean en la tabla 1.

Se pudo observar que el error depende de varios factores como ser la homogeneidad de los datos, la decisión de que modelo adoptar, los parámetros de la red y finalmente el tipo de solución. Para los resultados mostrados en la tabla 1 y en las figuras 5-8, se puede observar que los valores predichos no son tan diferentes a los valores reales con los que se cuenta para el rango de años estudiado.

También, se puede deducir que los resultados obtenidos demuestran que los modelos planteados, para cada mes del año, son confiables y precisos para poder estimar la demanda eléctrica horaria para la Ciudad de Salta.

5 Conclusiones y Trabajo Futuro

La previsión de la demanda juega un papel dominante en la optimización económica y el funcionamiento seguro de los sistemas de energía eléctrica. Esta, representa el primer paso en el desarrollo de instalaciones de generación, transmisión y distribución futuras. Cualquier desviación sustancial en el pronóstico, particularmente bajo la nueva estructura del mercado, resultará en la sobre construcción de las instalaciones de suministro o en la reducción de la oferta de los clientes. Es poco probable que los niveles de confianza asociados con las técnicas clásicas de pronóstico, cuando se aplican a problemas de pronóstico en servicios públicos maduros y estables, sean similares a los de los servicios públicos dinámicos y de rápido crecimiento.

Esto se atribuye a las diferencias en la naturaleza del crecimiento, las condiciones socioeconómicas, la ocurrencia de eventos especiales, las condiciones climáticas extremas y la competencia en la generación por la desregulación del sector eléctrico con posibles cambios en las estructuras tarifarias. En tales condiciones, estas técnicas de pronóstico son insuficientes para establecer el pronóstico de la demanda para la planificación del sistema eléctrico a largo plazo. En consecuencia, este caso requiere una consideración separada, ya sea persiguiendo la búsqueda de más mejoras en las técnicas de pronóstico existentes o estableciendo otro enfoque para abordar el problema de pronóstico de tales sistemas.

En este trabajo, se presentó un modelo basado en redes neuronales artificiales con el fin de poder pronosticar el consumo eléctrico horario, discriminado por mes, para la Ciudad de Salta. Los resultados de este modelo fueron sometidos a diversas técnicas estadísticas para poder determinar la validez estadística de los mismos. Obteniendo como resultado que los errores cometidos por el modelo se encuentran dentro de los márgenes consideramos como aceptables. Sin embargo y como se mencionó anteriormente, el modelo de pronóstico de energía eléctrica, fue desarrollado teniendo en cuenta datos pre-pandémicos, ya que se consideraron los datos hasta el año 2019. A pesar de estos últimos cambios y variables introducidas a nivel país, los modelos desarrollados resultan un gran aporte para la literatura de los temas abordados en este trabajo.

A partir de la situación de público conocimiento, resulta interesante poder estudiar el comportamiento de la demanda eléctrica en la Ciudad en relación a los diversos niveles de restricciones establecidos a lo largo de los años 2020 y 2021 y poder determinar un nuevo modelo que permita simular esta realidad. Como así también, una vez finalizada la pandemia, poder determinar cómo cambio el comportamiento humano frente al consumo eléctrico y poder de esta manera poder tomar decisiones para por un lado mejorar el sistema y por otro lado volver más rentable el sistema de generación y traslado de energía eléctrica en la Ciudad. Además, como trabajo futuro se propone una alternativa para trabajar con los valores continuos, mediante su transformación a datos categóricos, de tal manera de evaluar si mejora las predicciones del modelo.




Fig. 6. Estimaciones para el mes de Enero




Fig. 7. Estimaciones para el mes de Febrero

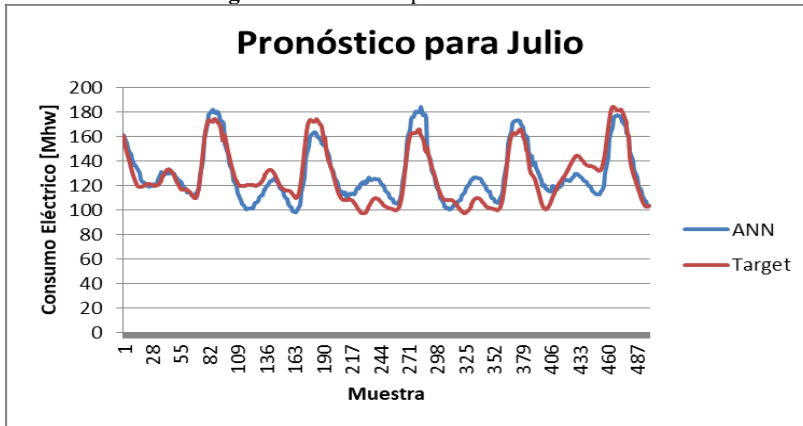


Fig. 8. Estimaciones para el mes de Julio




Fig. 9. Estimaciones para el mes de Agosto

Referencias

1. Schellong, W. (2011). Energy demand analysis and forecast. In: Kini G (editor). *Energy Management Systems*. Rijeka, Croatia: InTech.
2. Taylor, J.W. (2010) Triple seasonal methods for short-term electricity demand forecasting. *European Journal of Operational Research*.
3. Fan, S. & Hyndman, R.J. (2012) Short-term load forecasting based on a semi-parametric additive model. *IEEE Transactions on Power Systems*.
4. Hyndman, R.J. & Fan S. (2010) Density forecasting for long-term peak electricity demand. *IEEE Transactions on Power Systems*.
5. Chang, C.J., Lin, J.Y. & Chang, M.J. (2016). Extended modeling procedure based on the projected sample for forecasting short-term electricity consumption. *Advanced Engineering Informatics*.
6. Luo, X.J., Lukumon, O., Anuoluwapo, A., Chukwuka, M., Olugbenga, A. & Lukman, A. (2019) Development of an IoT-based big data platform for day-ahead prediction of building heating and cooling demands. *Advanced Engineering Informatics*.
7. Luo, X.J. (2020). A novel clustering-enhanced adaptive artificial neural network model for predicting day-ahead building cooling demand. *Journal of Building Engineering*.
8. Luo, X.J., Oyedele, L.O., Ajayi, A.O., Akinade, O.O., Delgado, J.M.D., Owolabi, H.A & Ahmed, A. (2020) Genetic algorithm-determined deep feedforward neural network architecture for predicting electricity consumption in real buildings. *Energy and AI*.
9. Imani, M., & Ghassemanian, H. (2019). Residential load forecasting using wavelet and collaborative representation transforms. *Applied Energy*. <https://doi.org/10.1016/j.apenergy.2019.113505>.
10. Hernández, L., Baladrón, C., Aguiar, J. M., Carro, B., Sánchez-Esguevillas, A., & Lloret, J. (2014). Artificial neural networks for short-term load forecasting in microgrids environment. *Energy*, 75, 252–264. <https://doi.org/10.1016/j.energy.2014.07.065>.
11. Marvuglia, A., & Messineo, A. (2012). Using recurrent artificial neural networks to forecast household electricity consumption. In *Energy Procedia* (Vol. 14, pp. 45–55). <https://doi.org/10.1016/j.egypro.2011.12.887>.
12. Day, P., Fabian, M., Noble, D., Ruwisch, G., Spencer, R., Stevenson, J., & Thoppay, R. (2014). Residential power load forecasting. In *Procedia Computer Science* (Vol. 28, pp. 457–464). <https://doi.org/10.1016/j.procs.2014.03.056>.
13. Amjady, N., & Keynia, F. (2011). A new neural network approach to short term load forecasting of electrical power systems. *Energies*, 4(3), 488–503. <https://doi.org/10.3390/en4030488>.
14. Meng, M., Niu, D., & Sun, W. (2011). Forecasting monthly electric energy consumption using feature extraction. *Energies*, 4(10), 1495–1507. <https://doi.org/10.3390/en4101495>.
15. He, W. (2014). Deep neural network based load forecast. *Computer Modelling & New Technologies*, 3(18), 258–262.

16. Wang, J.Q., Du, Y. & Wang, J. (2020) LSTM based long-term energy consumption prediction with periodicity. *Energy*.
17. Khafaf, N., Jalili, M. & Sokolowski, P. (2019). Application of deep learning long short-term memory in energy demand forecasting. In *International Conference on Engineering Applications of Neural Networks*. Springer.
18. Wang, X.H., Zhao, T., Liu, H. & He, R. (2019). Power consumption predicting and anomaly detection based on long short-term memory neural network. *IEEE 4th International Conference on Cloud Computing and Big Data Analytics (ICCCBDA)*.
19. Khan, Z.A., Hussain, T., Ullah, A., Rho, S., Lee, M. & Baik, S.W. (2020). Towards Efficient Electricity Forecasting in Residential and Commercial Buildings: A Novel Hybrid CNN with a LSTM-AE based Framework. *Sensors*.
20. Wei, N., Li, C., Peng, X., Li, Y. & Zeng, F. (2019). Daily natural gas consumption forecasting via the application of a novel hybrid model. *Applied Energy*.
21. Singaravel, S., Suykens, J. & Geyer, P. (2018) Deep-learning neural-network architectures and methods: Using component-based models in building-design energy prediction. *Advanced Engineering Informatics*.
22. Zhou, C., Fang, Z., Xu, X., Zhang, X., Ding, Y. & Jiang, X. (2020). Using long short-term memory networks to predict energy consumption of air-conditioning systems. *Sustainable Cities and Society*.
23. Compañía Administradora del Mercado Mayorista Eléctrico (CAMMESA). Informe Mensual: Principales Variables.