

Pronóstico de consumo de energía en ámbitos institucionales y domésticos

Patricio G. Donato et alles

Instituto de Investigaciones Científicas y Tecnológicas en Electrónica (ICYTE). CONICET - UNMDP
donatopg@fi.mdp.edu.ar

Nota del editor. El artículo aquí presentado fue expuesto originalmente en el marco de 28° Congreso Argentino de Control Automático AADECA '23 por los autores. Se trata de una investigación que surge a partir de la colaboración entre dos grupos de investigación. Por un lado, el Instituto de Investigaciones Científicas y Tecnológicas en Electrónica (ICYTE), dependiente del CONICET y la Universidad Nacional de Mar del Plata (UNMDP); por otro lado, el Grupo de Ingeniería Electrónica Aplicada a Espacios Inteligentes y Transporte (GEINTRA), de la Universidad de Alcalá (UAH).

Los autores son Rubén Nieto (ruben.nieto@urjc.es), del Departamento de Electrónica de la Universidad Rey Juan Carlos; Álvaro Hernández (alvaro.hernandez@uah.es) y Laura de Diego (laura.diego@uah.es), del Departamento de Electrónica de la Universidad de Alcalá, y Patricio G. Donato (donatopg@fi.mdp.edu.ar), Carlos M. Orallo (orallo@fi.mdp.edu.ar) y Marcos A. Funes (mfunes@fi.mdp.edu.ar), del Instituto de Investigaciones Científicas y Tecnológicas en Electrónica (ICYTE) de la Universidad Nacional de Mar del Plata.

La investigación y desarrollo de tecnologías para la mejora de la eficiencia energética ofrece un gran potencial para el uso de redes neuronales que pronostiquen variables eléctricas e identifiquen patrones de consumo. En este artículo se presentan los resultados preliminares del trabajo realizado sobre pronóstico de consumo de energía en las instituciones públicas y las viviendas familiares. Los resultados obtenidos sirven de base para avanzar en cuestiones más complejas, como es la generalización de las redes entrenadas.

La tendencia creciente de la demanda de energía eléctrica, impulsada por el crecimiento de la población y los hábitos de consumo de la sociedad moderna, crea incertidumbre sobre el panorama energético de los próximos años. La solución a esta problemática se encuentra en la generación a partir de fuentes alternativas y en un consumo racional, más eficiente.

La eficiencia energética es un tópico que está comprendido dentro de las redes eléctricas inteligentes (REI). Estas son la conjunción de la red eléctrica tradicional con las tecnologías de la información y comunicaciones (TIC), los sistemas de generación distribuida y el almacenamiento de energía. Entre otras características, las REI tienen que adquirir datos desde diferentes puntos de la red en tiempo real y a su vez ser capaces de actuar sobre la misma red. Esto implica manejar grandes volúmenes de datos provenientes de múltiples puntos de la red, además de hardware y software para procesarlos y extraer la información de interés.

Las REI tienen que adquirir datos desde diferentes puntos de la red en tiempo real y a su vez ser capaces de actuar sobre la misma red.

URL estable: <https://www.editores.com.ar/node/8096>




Figura 1. Esquema básico de la red neuronal entrenada, basada en el perceptrón multicapa (MLP).

En este trabajo se presenta parte de los resultados de un estudio realizado en conjunto entre dos grupos de investigación, enfocado tanto en ámbitos institucionales como domésticos. Para ello se ha trabajado con series de datos históricos de potencia consumida, tanto en instalaciones universitarias, como en un domicilio particular.

En un principio se pretende ajustar modelos de redes neuronales para hacer pronósticos de evolución de variables eléctricas que sean potencialmente útiles para gestión y control, tanto de parte de la distribuidora como por parte del cliente. Esto servirá de base para, en las siguientes instancias de la colaboración, trabajar sobre la capacidad de generalización de estas redes entrenadas en diferentes entornos.

Pronóstico de la demanda de potencia mediante redes neuronales

Hacer un pronóstico de series temporales significa que se extienden los valores históricos de una

serie (conocidos de antemano) a tiempos futuros, donde aún no existen mediciones de la variable de interés. Estos pronósticos se pueden hallar en dominios y aplicaciones muy diferentes [1] [2].

En un trabajo previo [3] se presentaron dos propuestas de redes neuronales, una basada en LSTM (del inglés, 'memoria de corto-largo plazo') y otra en perceptrones multicapa (MLP). Ambas tomaban solo la serie de datos temporales de potencia demandada, lo que hacía necesario que la red tuviese una cierta complejidad y que empleara una ventana de datos bastante extensa para registrar correctamente los patrones correspondientes a los días laborables, los fines de semana y los eventuales feriados. En este nuevo trabajo se propone una mejora, usando como datos de entrada también la identificación del día de la semana. Esta nueva información permite reducir notoriamente la ventana de datos necesaria para entrenar la red.

En un principio se pretende ajustar modelos de redes neuronales para hacer pronósticos de evolución de variables eléctricas que sean potencialmente útiles para gestión y control

Red MLP

La red MLP emplea veinticuatro muestras de potencia previas, las cuales se adquieren cada media hora, por lo cual implica que el pronóstico se hace a partir de las últimas doce horas. La primera capa densa tiene noventa y seis neuronas, seguida a continuación de otra capa densa con

Épocas	Batch	Loss	RMS (train)	RMS (test)
64	16	$3,302 \times 10^{-4}$	3,66 kW	3,81 kW

Tabla 1. Resultados de entrenamiento y test de la red MLP.

Épocas	Batch	Loss	RMS (train)	RMS (test)
64	16	$3,33 \times 10^{-4}$	3,73 kW	3,91 kW

Tabla 2. Resultados de entrenamiento y test de la red LSTM.




Figura 2. Pronósticos de demanda de potencia activa por fase (L1, L2 y L3), empleando las redes MLP y LSTM entrenadas en la sección previa.

veinticuatro neuronas en donde se agrega la información del día (ver figura 1). Se disponía de un conjunto de 26.458 mediciones de potencia activa total, correspondientes a casi ochenta semanas, adquiridas entre 2018 y 2020, las cuales se dividieron en 67% para entrenamiento y 33% para test. Se excluyeron las mediciones correspondientes al comienzo de la etapa de aislamiento producto de la pandemia de Covid19, por considerar que no representaban el comportamiento normal de la demanda de las instalaciones universitarias. En la tabla 1 se resumen algunos de los parámetros del entrenamiento y test. Se observó que los errores más importantes se produjeron durante los cambios abruptos del consumo, como los que corresponden al inicio y la finalización de la jornada laboral.

Red LSTM

Al igual que en el caso de la MLP, para la red LSTM se emplean veinticuatro muestras de potencia previas, adquiridas cada media hora. La primera capa densa tiene veinticuatro celdas LSTM, seguida a continuación de una capa densa con cuarenta y ocho neuronas en donde se agrega la información del día. Los datos de entrenamiento y test fueron los mismos que los usados en la red MLP, distribuidos en la misma proporción y sin emplear datos adquiridos durante la pandemia. En la tabla 2 se resumen los correspondientes parámetros del entrenamiento y test.

Al igual que en el caso de la red MLP, en la red LSTM se observó que los errores de pronóstico más importantes se produjeron durante los cambios abruptos del consumo, como los que se dan al comienzo y la finalización de la jornada laboral. Exceptuando estos errores transitorios, el resto del tiempo el pronóstico tiene un error acotado menor a 4 kW.

Al igual que en el caso de la red MLP, en la red LSTM se observó que los errores de pronóstico más importantes se produjeron durante los cambios abruptos del consumo

Pronóstico de la demanda de potencia por fase

Las redes entrenadas en la sección previa usaban como datos de entrada la potencia activa total demandada en el edificio de INTEMA durante las últimas doce horas y el dato de identificación del día de la semana. Partiendo de este diseño, se planteó la hipótesis de que la misma red podría emplearse para hacer pronósticos de los consumos individuales en cada fase, no solo de la potencia activa sino también de la reactiva. Si bien el análisis de las series temporales de potencia demandada por fase mostraba cierta similitud en

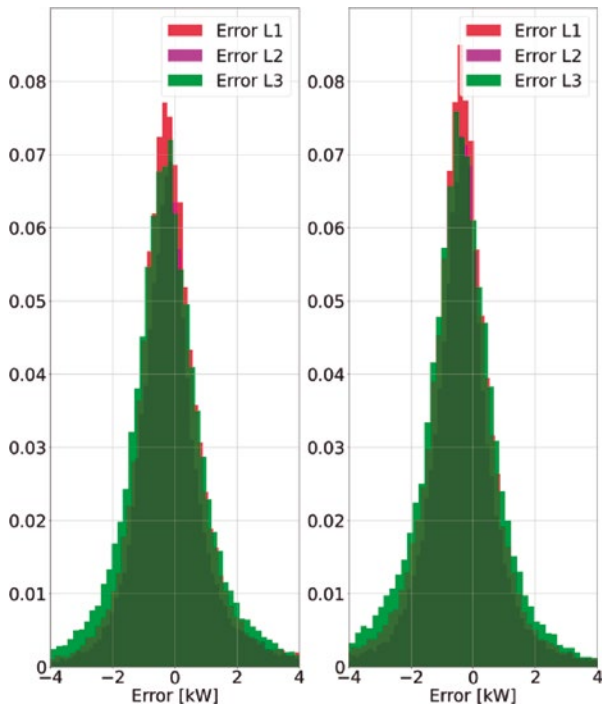


Figura 3. Histogramas del error de pronóstico de potencia activa por fase usando las redes MLP (izquierda) y LSTM (derecha) propuestas.

el comportamiento, también el relevamiento de datos había mostrado un fuerte desbalance entre las corrientes de fase, que oscilaba entre el 8 y el 30% (relación entre componente de secuencia negativa y positiva de la terna de corrientes de fase), lo cual podía influir en el pronóstico.

Pronóstico de potencia activa por fase empleando redes MLP y LSTM

En la figura 2 se puede observar el pronóstico de potencia activa por fase para la semana del 3 al 10 de agosto de 2019, usando tanto la red MLP como la LSTM. En primer lugar, las curvas de pronóstico de las redes MLP y LSTM son casi indistinguibles entre sí, esto es, sus pronósticos son casi idénticos. Al igual que en el caso de la potencia total, evaluado en la sección anterior, se observa




Figura 4. Pronóstico de demanda de potencia reactiva por fase (L1, L2 y L3), empleando las redes MLP y LSTM entrenadas en la sección previa.

que el error tiene la mayor desviación al comienzo y la finalización del horario laboral en las instalaciones.

En la figura 3 se pueden apreciar dos histogramas del error de pronóstico para las tres fases y ambas redes neuronales. Puede verse que ambos histogramas no están centrados en cero, sino que muestran un leve desplazamiento a valores negativos del error, del orden de cientos de watts y que las tres fases tienen una distribución similar, con una ligera diferencia entre las fases L1 y L2 respecto de la L3. El rango mostrado en la figura comprende más del 98,3% de los valores de error registrados en esa semana para el caso de la red MLP, y más del 99% para el caso de la red LSTM. Esto significa que los errores mayores a 4 kW representan menos del 2% del error en di-

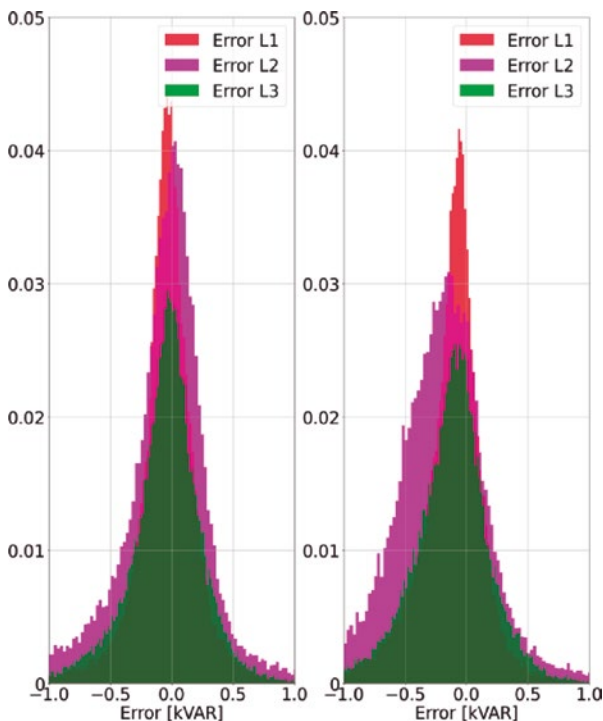


Figura 5. Histogramas del error de pronóstico de potencia reactiva por fase usando las redes MLP (izquierda) y LSTM (derecha) propuestas.

cho período para las redes MLP, y menos del 1% para el caso de las LSTM.

Es posible llevar a cabo un enfoque basado en la predicción o regresión para el consumo de energía general de la vivienda, pero esta aproximación no es viable para el consumo particular de la mayoría de los electrodomésticos

Pronóstico de potencia reactiva por fase empleando redes MLP y LSTM

En la figura 4 se puede observar el pronóstico de potencia reactiva por fase para la misma semana mostrada en la subsección previa. El comportamiento del error es similar al observado en los ensayos anteriores, tanto en lo que refiere a los ciclos laborales como en el comportamiento frente a los cambios en la demanda. Los pronósticos de ambas redes son prácticamente indistinguibles entre sí.

En la figura 5 se pueden apreciar los histogramas correspondientes al error de pronóstico para las tres fases y ambas redes neuronales. Puede verse que ambos histogramas no están centrados en cero, sino que muestran un leve desplazamiento a valores negativos del error. Se observa una notoria diferencia en el valor máximo del histograma (principalmente entre L1 y L3), así como en la dispersión, que es mayor en la fase L2. Respecto del desplazamiento del valor máximo, es más pronunciado en el caso de la red LSTM, donde el valor máximo se halla centrado en torno a los -200 VAR para la fase L2. En los dos pronósticos se observa un menor error en la estimación de la fase L3. El rango mostrado en la figura comprende al 99% de los valores de error registrados en esa semana para el caso de la red MLP, y más del 99% para el caso de la red LSTM. Esto significa que los errores mayores a 1 kVAR representan menos del 1% de los errores en dicho período.




Figura 6. Consumo eléctrico general, de la lavadora y del lavavajillas durante el periodo inicial de seis semanas.

Pronósticos de demanda en el ámbito doméstico

La otra parte del estudio fue realizada por el grupo GEINTRA en el ámbito de una vivienda familiar, empleando las mismas soluciones tecnológicas. En las últimas décadas se ha producido el paulatino despliegue en los hogares de dispositivos inteligentes. La primera utilidad fue la gestión del consumo eléctrico y el diseño de estrategias para maximizar la eficiencia energética.

En el curso de los últimos años ha surgido con fuerza la idea de emplear las técnicas de monitoreo no intrusivo de la demanda (NILM, por sus siglas en inglés) para identificar los eventos de activación y desactivación de los distintos aparatos eléctricos existentes en una vivienda. Los patrones de uso identificados sirven como herramientas, no solo útiles para aumentar la eficiencia energética, sino para aplicaciones de índole socio-sanitaria de asistencia para la vida independiente de adultos mayores [4] [5] [6].

En este contexto, se ha monitorizado durante un periodo de diecisiete meses (de noviembre de 2020 a marzo de 2022) una vivienda en la región de Madrid, habitada por una familia compuesta por dos adultos y dos adolescentes. Para la captura de datos, se ha instalado a la entrada de la vivienda un dispositivo Wibeee Box Mono [7], que proporciona, no solo el consumo total de la vivienda, sino también el consumo desagregado para los aparatos eléctricos más significativos de la misma, a intervalos de una hora. En la figura 6 se muestra un intervalo de seis semanas, desde el 2 de noviembre de 2020 hasta el 13 de diciembre de 2020.

En la parte superior se puede observar el consumo global de la vivienda, mientras que a continuación se muestra la energía desagregada correspondiente a la lavadora y al lavavajillas. A partir de estos datos, se puede concluir que es posible llevar a cabo un enfoque basado en la predicción o regresión para el consumo de energía general de la vivienda, pero esta aproximación no es viable para el consumo particular de




Figura 7. Red neuronal basada en celdas LSTM propuesta para la predicción del consumo eléctrico general de la vivienda bajo análisis.

la mayoría de los electrodomésticos, donde se producen activaciones esporádicas de forma diaria o semanal. Solo aquellos aparatos eléctricos que presenten una cierta regularidad a lo largo del día (como es el caso del frigorífico) son susceptibles de ser analizados mediante técnicas de regresión.

Centrando el estudio en primer lugar en el consumo general de la vivienda, se propone a continuación una red neuronal profunda del tipo LSTM que sea capaz de predecir dicho valor, según la arquitectura mostrada en la figura 7. Se ha elegido la topología recurrente LSTM, tratando de que el sistema sea capaz de aprender las rutinas cíclicas que existen en el consumo eléctrico de la vivienda a lo largo de las semanas. En ese sentido, la serie temporal de entrada a la red




Figura 8. Energía consumida y predicha a partir de la red LSTM para la última semana disponible en marzo 2022.

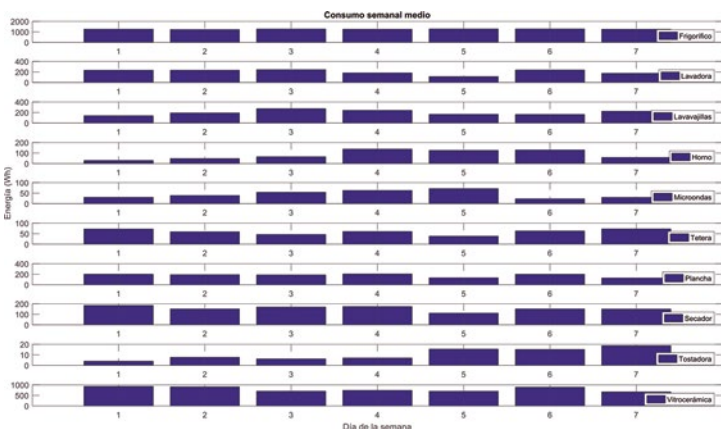


Figura 9. Consumo semanal medio por día para los distintos electrodomésticos desagregados en la casa bajo estudio.

neuronal tiene un histórico de los últimos catorce días, con un total de veinticuatro muestras diarias. Además, para particularizar los comportamientos distintos que tiene la vivienda entre días laborables y fines de semana, la capa densa de salida tiene como entradas el día de la semana y la hora del día actuales. La complejidad de la red viene definida por un total de 29.697.061 parámetros entrenables.

Esta red fue entrenada con los datos disponibles de la vivienda para diecisiete meses, de los cuales el 60% fueron dedicados al entrenamiento, el 20% a la validación y el otro 20% al test. La red




Figura 10. Consumo diario medio cada hora para los distintos electrodomésticos desagregados en la casa bajo estudio.

fue entrenada con un optimizador Adam, incluyendo una tasa de aprendizaje de 10-5, un decay de 10-6, y una función de pérdidas a partir del error absoluto medio. A partir de los datos de test (desde el 13 de diciembre de 2021 hasta el 21 de marzo de 2022) se ha comparado la diferencia entre la energía consumida y el pronóstico, obteniéndose un error absoluto medio de 0,069 y un error cuadrático medio de 0,013, para una energía de entrada normalizada. La figura 8 muestra a modo de ejemplo ambos valores, consumido y predicho, para la última semana del periodo evaluado en marzo 2022. Conviene destacar cómo el consumo de la vivienda presenta picos de energía, normalmente asociados al uso de electrodomésticos de gran consumo (lavavajillas, horno, vitrocerámica, etc.), cuyo uso no es sistemático a lo largo de los días, de ahí la dificultad en su aprendizaje. De esta forma, la señal predicha refleja bien los cambios de consumo entre las franjas diurnas y nocturnas, pero presenta dificultades para estimar las activaciones de esos grandes electrodomésticos.

Desde un punto de vista más social, existe la posibilidad de analizar cómo se comporta el consumo de cada uno de los aparatos eléctricos durante determinados períodos, para poder establecer pautas de comportamiento de los inquilinos, y detectar posteriormente cualquier desviación para generar las correspondientes alarmas. En este sentido, trabajando sobre los datos procedentes de la misma vivienda, la figura 9 muestra el consumo medio para cada día de la semana de los electrodomésticos desagregados. Este gráfico muestra ciertas tendencias, como el hecho de que la tostadora tiende a emplearse con mayor frecuencia durante el fin de semana, al contrario que el microondas o el secador de pelo que son más habituales en los días laborables. Otro enfoque similar se muestra en la figura 10, donde se ve la energía media consumida por cada electrodoméstico a lo largo de las veinticuatro horas del día. Aquí es posible observar patrones de uso a priori habituales, como el uso matutino de la lavadora o la tostadora, en el empleo del horno

asociado a la preparación de la comida y la cena, o la activación del microondas asociado a las tres comidas principales del día (desayuno, comida y cena). Además, se puede observar cómo las horas nocturnas casi no muestran actividad, a excepción del lavavajillas, y en menor medida la lavadora, que presentan cierta actividad derivada de un inicio de un ciclo que comenzó en las últimas horas del día anterior y se prolongó en la madrugada siguiente.

Por otro lado, otra posibilidad es acometer el análisis de forma individual para cada uno de los aparatos eléctricos. En este contexto, y dependiendo de cada vivienda y persona, es posible identificar que algunos electrodomésticos son empleados de forma sistemática y más rutinaria, lo cual los hace candidatos ideales para la generación de posibles alarmas derivadas de la detección de anomalías en el comportamiento. A modo de ejemplo, y de forma particular para esta vivienda, se ha realizado un estudio centrado en el microondas. En la figura 11, en la parte superior se muestra el perfil porcentual del consumo de este electrodoméstico a lo largo de todo un día. En ella se observa una predominancia clara en tres intervalos horarios relacionados con el desayuno, comida y cena. Otra forma de presentar esta información se refleja en la gráfica inferior, donde se representa un porcentaje acumulado.

Sobre la información de la figura 11, se puede fijar un umbral (a modo de ejemplo fijado en el valor de 0,4 reflejado con una línea roja discontinua), que determina la hora límite (las 13 h) a la cual ya debería haberse activado el microondas. Si en una jornada concreta, este electrodoméstico no se utiliza antes de esa hora, el sistema detectará la situación anómala correspondiente y podrá emitir una notificación a las personas interesadas. Este funcionamiento se describe en la figura 12, donde se muestra el comportamiento de este sistema de detección de anomalías a lo largo de una semana final en el periodo registrado. Se puede comprobar cómo en los primeros días laborables de la semana el microondas es

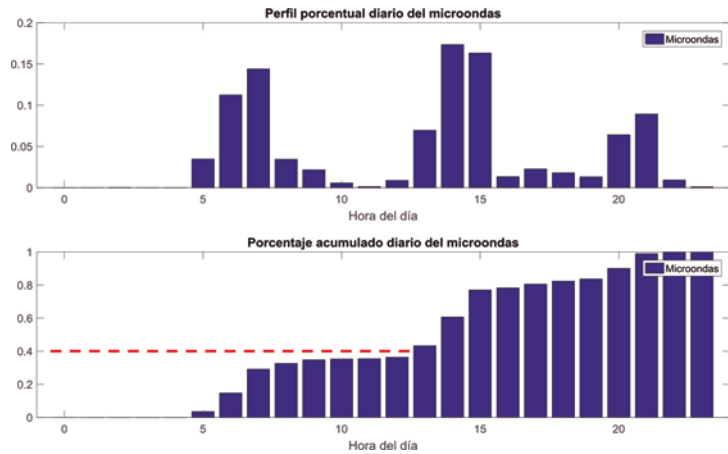


Figura 11. Consumo horario medio normalizado del microondas (arriba), y representación porcentual acumulada para un día (abajo).

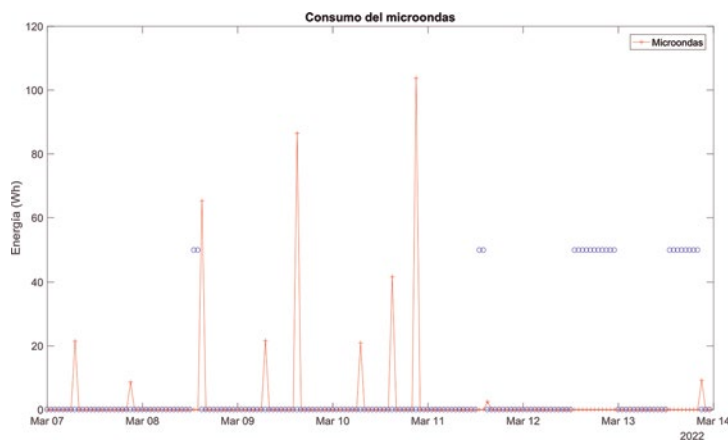


Figura 12. Ejemplo del consumo del microondas en una semana de marzo de 2022, y detección de las anomalías correspondientes a su uso diario.

activado antes de la hora umbral, pero la situación cambia hacia el fin de semana, generándose las correspondientes alarmas (círculos azules). Nótese que el umbral de 0,4 puede modificarse para ajustar más finamente la sensibilidad deseada en función de cada caso particular.

Ambas estructuras se han desempeñado con solvencia y de forma similar en la estimación del consumo eléctrico del edificio

Conclusiones

Este trabajo ha abordado el pronóstico del consumo eléctrico de un edificio o vivienda, desde dos ámbitos de aplicación diferentes. Por un lado, se ha estudiado un edificio público universitario, en el que se han propuesto dos tipologías distintas de redes neuronales profundas, una de tipo recurrente LSTM y otra perceptrón multicapa. Ambas estructuras se han desempeñado con solvencia y de forma similar en la estimación del consumo eléctrico del edificio a partir de su serie histórica, alcanzando errores relativos bajos. Además, el estudio se ha particularizado con éxito, no solo para las tres fases del edificio, sino también para la potencia activa y reactiva. Por otro lado, se ha analizado una vivienda particular, mediante la instalación a la entrada de la misma de un medidor inteligente. Este proporciona, no solo la medida general de consumo eléctrico, sino también la energía desagregada por electrodoméstico. Esta información ha sido empleada para monitorizar de forma preliminar los patrones de uso de los electrodomésticos en la vivienda, y proponer un sistema de detección de situaciones anómalas a partir del análisis de los aparatos eléctricos más representativos. ■

Referencias

- [1] R.H. Shumway, D.S. Stoffer, "Time Series Analysis and Its Applications", 2o edición, Springer (2006).
- [2] Prasad, A; Kay, M, "Assessment of simulated solar irradiance on days of high intermittency using WRF-solar", *Energies* (2020), 13, 385
- [3] P.G. Donato, M.A. Funes, C.M. Orallo, N.I. Echeverría, "Pronóstico de variables eléctricas en el marco del proyecto de ciudades inteligentes en Mar del Plata", IEEE Argencon 2022. 7-9 de septiembre de 2022 – San Juan (Argentina).
- [4] N. Noury, M. Berenguer, H. Teyssier, M. J. Bouzid and M. Giordani, "Building an index of activity of inhabitants from their activity on the residential electrical power line", *IEEE Trans. on Information Technology in Biomedicine*, vol. 15, pp. 758-766, 2011.
- [5] A. Ruano, A. Hernández, J. Ureña, M. Ruano, and J.J. García, "NILM Techniques for Intelligent Home Energy Management and Ambient Assisted Living: A Review", *Energies*, vol. 12, pp. 2203, 2019.
- [6] Y. Nakaoku, S. Ogata, S. Murata, M. Nishimori, M. Ihara, K. Iihara, M. Takegami and K. Nishimura, "AI-Assisted In-House Power Monitoring for the Detection of Cognitive Impairment in Older Adults", *Sensors*, vol. 21, pp. 6249, 2021.
- [7] Smilics Technologies, S. L., Wibee Box Mono, Technical Description, 2021.

Nota de los autores

Este trabajo fue apoyado por la Universidad Nacional de Mar del Plata (UNMDP), el Consejo Nacional de Investigaciones Científicas y Tecnológicas (CONICET) PIP11220200102643CO y por la Agencia Nacional de Promoción Científica y Tecnológica (ANPCYT), Argentina.

Del otro lado, el trabajo ha sido financiado por el Ministerio de Ciencia e Innovación (proyectos PoM, ref. PID2019-105470RA-C33, ALONE, ref. ED2021-131773B-I00, e INDRI, ref. PID2021-122642OB-C41), España. Patricio G. Donato agradece el apoyo de la convocatoria Bec.ar, que le permitió realizar una estancia de investigación en el GEINTRA durante el año 2022.