

Monitoreo de carga por métodos no invasivos en el hogar argentino utilizando redes neuronales

Diego Cocconi*, Raúl Beinotti*, Rebeca Yuan*, Micaela Mulassano*, Javier Bruno*, Matías Beltramone*.

Departamento de Ingeniería en Sistemas de Información / Facultad Regional San Francisco /
Universidad Tecnológica Nacional (UTN)
Av. de la Universidad 501, 2400, San Francisco, Córdoba, Argentina, (03564) 431019 / 435402
*{dcocconi, rbeinotti, ryuan, mmulassano, jbruno, mbeltramone}@sanfrancisco.utn.edu.ar

Resumen

En la actualidad, mucha gente podría verse interesada en el monitoreo energético de sus viviendas, con el fin de optimizar sus consumos. De esta manera, se conocerían los artefactos eléctricos que más energía consumen, su incidencia en el tiempo, cuán representativo resulta el consumo del resto de los artefactos y aquellos artefactos que podrían estar fallando.

Utilizando Non-Intrusive Load Monitoring (NILM) y redes neuronales (del inglés Artificial Neural Networks, ANN), el presente proyecto propone ofrecer esta posibilidad.

Palabras clave: identificación de carga, monitoreo de energía, NILM, redes neuronales.

Contexto

El presente trabajo forma parte del proyecto de investigación I+D UTN 4881 “Monitoreo domiciliario utilizando redes neuronales a partir de una medición de energía totalizada (NILM)”. El mismo está homologado como proyecto de investigación y desarrollo en la Secretaría de Ciencia, Tecnología y Posgrado de la Universidad Tecnológica Nacional. En el marco de dicho proyecto se propone implementar NILM mediante *machine learning* para el análisis del consumo de energía en los hogares argentinos, a través de la utilización de redes neuronales artificiales.

1. Introducción

En la actualidad, mucha gente podría verse interesada en el monitoreo energético de sus viviendas, con el fin de optimizar sus consumos. Dos enfoques fueron planteados para realizar tal monitoreo [1]: (1) la utilización de medidores independientes para cada artefacto eléctrico; (2) la aplicación de *Non-Intrusive Load Monitoring* (NILM) [2] o *Non-Intrusive (Appliance) Load Monitoring* (NIALM o NALM) [3]. NILM es una técnica computacional que a partir de una medida total de consumo de energía logra identificar los artefactos eléctricos individuales que se encuentran consumiendo la misma [4]; aunque midiendo cada artefacto puede resultar un método más exacto que NILM, las desventajas prácticas como elevados costos, múltiples configuraciones de sensores y complejidad en la instalación, favorecen el uso de esta técnica [5].

Un enfoque comúnmente utilizado para implementar NILM involucra las siguientes etapas: (1) *adquisición de datos*; (2) *extracción de features*; e (3) *inferencia o aprendizaje*. Durante esta última etapa, las diversas *features* de los artefactos eléctricos extraídas a partir de los datos de consumo son procesadas según diferentes algoritmos en orden de identificar los artefactos. Se suelen emplear técnicas supervisadas de *machine learning* en esta etapa, las cuales requieren datos etiquetados [5]; estas técnicas generalmente implican un proceso de aprendizaje lento y son vulnerables a cambios en el inventario de artefactos [1].

Por lo detallado anteriormente, se requieren abordajes que permitan obtener resultados más exactos, sin insumir tiempos prolongados de entrenamiento ni muchos recursos, e independientes de grandes inventarios de *features* de artefactos eléctricos.

2. Líneas de Investigación, Desarrollo e Innovación

Siguiendo la línea de investigación correspondiente a lo expuesto en este trabajo, se llevarán a cabo actividades relacionadas con las siguientes áreas temáticas:

- Ingeniería de Software.
- Mediciones Eléctricas.
- Eficiencia y Calidad de Energía Eléctrica.

3. Objetivos y Resultados Esperados

Resulta difícil para los usuarios de artefactos eléctricos determinar su consumo real de acuerdo a las condiciones de uso; en consecuencia, también es complejo determinar la incidencia de su uso a través del tiempo (diariamente, mensualmente, estacionalmente, etc.). Poder distinguir entre artefactos eléctricos con consumos importantes y aquellos que forman parte de un "piso" que no genera grandes consumos (como por ejemplo, *notebooks*, impresoras, etc.) puede resultar interesante para el usuario, básicamente por tres razones: (1) quedarían identificados los *artefactos que más consumen y su incidencia en el tiempo*, lo cual podría ayudar a moderar su uso; (2) se sabría si el *consumo de este "piso" puede resultar significativo*; y (3) podrían *detectarse aquellos artefactos con posibles fallas*.

Se plantea entonces ofrecer esta posibilidad al usuario de un modo que no implique dificultades ni complejidad adicional. Utilizando NILM la complejidad para el usuario se reduciría considerablemente; en tal caso, sería necesario identificar cada artefacto en una

medida de consumo total y determinar su consumo individual. Técnicas de *machine learning* como las *redes neuronales* (del inglés *Artificial Neural Networks*, ANN) han demostrado ser útiles para esta tarea. Sin embargo, la introducción de ANN conlleva desafíos adicionales: evitar que la arquitectura de la red resulte difícilmente entrenable, poco generalizadora ante nuevos artefactos y poco generalizadora para todos los comportamientos de un mismo artefacto. Entonces, se cuestiona que, ampliando los datos de la medición de consumo total con información proveniente de la extracción de *features* y utilizando dicho conjunto como entrada a la ANN, esto puede enriquecer la calidad de respuesta de la red, evitando problemas específicos inherentes a la misma.

En resumen, el principal objetivo de la línea de investigación propuesta es la identificación eficiente de los artefactos encendidos en la línea eléctrica de una vivienda mediante la aplicación de una ANN, pudiendo a través del tiempo determinar su consumo individual del modo más exacto posible, sin intervenir en el interior del hogar.

Para la consecución de este objetivo general, deberán tenerse en cuenta los siguientes objetivos específicos:

1. Modelar un sistema que permita la identificación de los artefactos eléctricos en uso dentro de una vivienda (los más importantes o representativos) a partir de la medida del consumo total de energía, utilizando una ANN.
2. Modelar un sistema que permita determinar el consumo de los artefactos identificados.
3. Modelar un sistema que permita determinar el consumo total de aquellos artefactos no tan importantes, no representativos o no identificados, que forman parte de un "piso".
4. Definir un sistema de almacenaje, recuperación y procesamiento de datos para proporcionar el consumo histórico de un artefacto y detectar fallas.
5. Definir un sistema de almacenaje, recuperación y procesamiento de datos

para determinar patrones de consumo (por ejemplo, patrones de consumo en invierno, en verano, etc.) de un artefacto.

- Proponer una arquitectura de ANN que permita satisfacer cuestiones referidas a la calidad de su respuesta: evitar que resulte difícilmente entrenable, poco generalizadora ante nuevos artefactos y poco generalizadora para todos los comportamientos de un mismo artefacto.

Para materializar el objetivo principal de este proyecto se propone una metodología “*design science research*” [13], pues provee un marco de trabajo ampliamente aceptado para realizar investigaciones relacionadas con sistemas de información, centrándose en resolver problemas por medio del diseño y desarrollo de artefactos.

La investigación comienza con un enfoque centrado en problemas, por lo que la etapa inicial consistió en definir problemas de investigación, hipótesis y objetivos. La segunda etapa implicará definir los artefactos para satisfacer los objetivos específicos.

Considerando el primer objetivo, se tendrán en cuenta tres fases: (1) *construcción del sistema NILM*; (2) *recolección y preparación de datos* para el entrenamiento de la ANN; y (3) *desarrollo de un entorno de pruebas* para comparar el desempeño de la red con otras alternativas conocidas.

La fase de construcción del sistema NILM precisará la elección de sensores de corriente y de voltaje; se analizarán *sensores de efecto Hall* y *sensores de efecto capacitivo*. Luego se evaluarán acondicionadores de señal apropiados (*amplificadores operacionales*, *amplificadores de instrumentación*, etc.). Seguidamente, se considerarán *convertidores AD* y entornos de desarrollo de sistemas electrónicos (*Arduino*, *Raspberry Pi*, etc.), conjuntamente con sus sistemas operativos soportados, que permitan implementar una microcomputadora. Se evaluarán luego lenguajes de programación (*C*, *Java*, *Matlab*, *Python*) y sus respectivos *frameworks/librerías* para implementar una función que permita la extracción de *features* y para implementar la ANN. Para mostrar la

información al usuario se tendrán en cuenta *pantallas LCD* y *conexión TCP/IP*. Un esquema de la arquitectura tentativa se ilustra en Fig. 1.

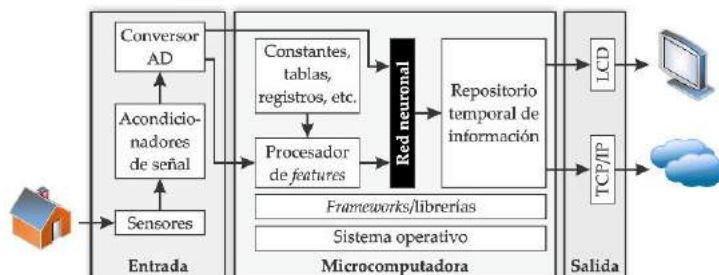


Fig. 1: Arquitectura del sistema NILM propuesto.

La segunda fase (recolección y preparación de datos) comenzará con la selección de un *analizador de potencia* o una *placa de adquisición de datos* que permita muestrear el consumo de un artefacto eléctrico en particular, con el nivel de detalle adecuado (baja frecuencia o alta frecuencia) y almacene dichos datos, para su posterior transmisión a una PC. El formato de almacenamiento de los datos en la PC será el utilizado por el MIT en el *dataset* de referencia REED¹. Una vez recopilados los datos para diversos artefactos, se procederá a su transformación en un esquema más adecuado para el entrenamiento de la red; se evaluarán bases de datos relacionales (*MySQL*, *SQL Server*, *PostgreSQL*). Una vez disponibles los datos en la base de datos, se considerarán diferentes lenguajes de programación (*C#*, *Java*, *Matlab*, *Python*) para identificar los ciclos de activación de cada artefacto, etiquetar los datos y definir una plataforma de entrenamiento para la ANN.

Las actividades de la tercera fase (desarrollo de un entorno de pruebas) incluyen utilizar la base de datos elegida y evaluar diferentes lenguajes de programación (*C#*, *Java*, *Matlab*, *Python*) para definir una plataforma de pruebas para la ANN, con el fin de comparar la alternativa propuesta con otros algoritmos conocidos y medir el desempeño utilizando diferentes métricas (*F1*, *precision*,

¹ <http://redd.csail.mit.edu/>

recall, accuracy) [4, 6].

Acerca del segundo objetivo, se desarrollará en el lenguaje de implementación utilizado en la ANN del primer objetivo, el algoritmo adecuado para calcular el consumo de cada artefacto eléctrico identificado.

Para el tercer objetivo, se desarrollará en el lenguaje de implementación utilizado en la ANN del primer objetivo, el algoritmo adecuado para calcular el consumo de aquellos artefactos eléctricos no tan importantes, no representativos o no identificados (“piso”).

Sobre el cuarto objetivo, se evaluarán bases de datos relacionales (*MySQL, SQL Server, PostgreSQL*), diferentes lenguajes de programación para desarrollo web (*HTML, JavaScript, PHP, Python*) y sus respectivos *frameworks* (*Laravel, Django*) para implementar una aplicación Web que permita comparar consumos históricos y determinar fallas en los artefactos eléctricos. En Fig. 2 se puede apreciar un esquema de la arquitectura tentativa del sistema Web.

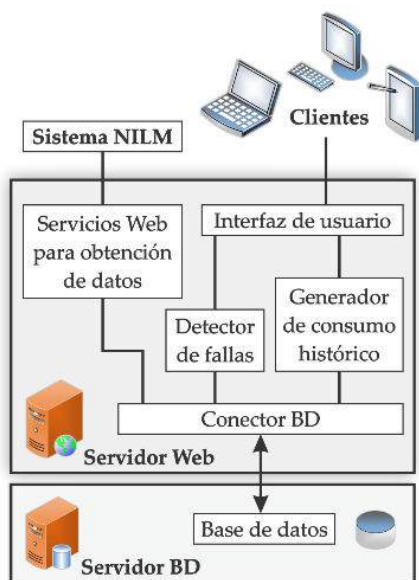


Fig. 2: Arquitectura del sistema Web propuesto.

Teniendo en cuenta el quinto objetivo, mediante la base de datos, el lenguaje de programación Web y su *framework* del cuarto objetivo, implementar una aplicación Web que permita determinar patrones de consumo de los artefactos.

Finalmente, para hacer frente al sexto objetivo, se evaluarán diferentes arquitecturas de ANN, sobre todo *deep neural networks: Restricted Boltzmann Machines (RBM), Deep Belief Networks (DBN), AutoEncoders (AE), deep Convolutional Neural Networks (CNN), Recurrent Neural Networks (RNN)* [4, 7]; además, se evaluarán diferentes *features* que podrían ayudar a mejorar el desempeño de la red.

La etapa final del proyecto consistirá en validar si los artefactos obtenidos permiten solucionar satisfactoriamente los problemas planteados.

4. Formación de Recursos Humanos

El grupo de esta línea de investigación está conformado por docentes y alumnos de las carreras de Ingeniería en Sistemas de Información, Electrónica y Electromecánica.

De los docentes involucrados en el proyecto, uno de ellos se encuentra cursando un Doctorado de Ingeniería con mención en Sistemas de Información, en la UTN Facultad Regional Santa Fe. Dos de las docentes dictan la cátedra Inteligencia Artificial (Ingeniería en Sistemas de Información) en la UTN Facultad Regional San Francisco, donde se encuentran realizando sus tesis para las Maestrías en Ingeniería de Software y Calidad de Software.

Como iniciativa del grupo, se prevé la capacitación y formación de recursos humanos, por medio de las siguientes actividades:

- Participación en cursos de actualización y posgrado en el área de estudio (*machine learning* e inteligencia artificial).
- Transferencia de conocimiento y resultados a otras áreas de la facultad y a la industria local.
- Incorporar el conocimiento adquirido en las cátedras referentes a la temática planteada.
- Ofrecer charlas informativas del desarrollo e implementación del proyecto a distintos sectores de la industria y cátedras afines a la investigación.

- Convocar e introducir a los alumnos de las carreras de Ingeniería en Sistemas de Información, Electrónica y Electromecánica a la realización de actividades de investigación y desarrollo.

5. Referencias

- [1] Xu, W., Dong, M., Meira, P., y Freitas, W. (2014, Julio). "An event window based load monitoring technique for smart meters". En: PES General Meeting| Conference & Exposition, 2014 IEEE (pp. 1-1). IEEE.
- [2] Hart, G. W. (1992). "Nonintrusive appliance load monitoring". Proceedings of the IEEE, 80(12), 1870-1891.
- [3] Bernard, T., y Marx, M. (2016). "Unsupervised Learning Algorithm using multiple Electrical Low and High Frequency Features for the task of Load Dis-aggregation". En: Proceedings of the 3rd international workshop on NILM.
- [4] Kelly, J., y Knottenbelt, W. (2015, Noviembre). "Neural nilm: Deep neural networks applied to energy disaggregation". En: Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environ-ments (pp. 55-64). ACM.
- [5] Zoha, A., Gluhak, A., Imran, M. A., y Rajasegarar, S. (2012). "Non-intrusive load monitoring approaches for disaggregated energy sensing: A survey". Sensors, 12(12), 16838-16866.
- [6] Makonin, S., y Popowich, F. (2015). "Nonintrusive load monitoring (NILM) performance evaluation". Energy Efficiency, 8(4), 809-814.
- [7] Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y., y Alsaadi, F. E. (2017). "A survey of deep neural network architectures and their applications". Neurocomputing, 234, 11-26.