

Aplicación de una arquitectura de red neuronal para el monitoreo de carga por métodos no invasivos (NILM) utilizando ciclos de activación de artefactos eléctricos en el entrenamiento

Diego Cocconi*, Rebeca Yuan*, Micaela Mulassano*, Diego Ferreyra*

Departamento de Ingeniería en Sistemas de Información / Electromecánica
Universidad Tecnológica Nacional (UTN), Facultad Regional San Francisco
San Francisco (2400), Córdoba, Argentina

*{dcocconi, ryuan, mmulassano, dferreyra}@sanfrancisco.utn.edu.ar

Resumen

Con el objetivo de lograr identificar artefactos eléctricos utilizando redes neuronales a partir de una medida total de consumo de energía (técnica conocida como NILM, del inglés *Non-Intrusive Load Monitoring*), en el presente trabajo se plantea la evaluación de dos tipos de redes neuronales capaces de realizar tal tarea, contando como ejemplos de entrenamiento válidos para el aprendizaje con ciclos de activación de diferentes artefactos que ya fueron identificados por un algoritmo de detección desarrollado en trabajos anteriores.

Palabras Claves: NILM – consumo de energía – ciclos de activación – aprendizaje automático – redes neuronales

CONTEXTO

El presente trabajo forma parte del proyecto de investigación I+D UTN CCUTNSF0004881 “*Monitoreo domiciliario utilizando redes neuronales a partir de una medición de energía totalizada (NILM)*”. El mismo está homologado como proyecto de investigación y desarrollo por la Secretaría de Ciencia, Tecnología y Posgrado de la Universidad Tecnológica Nacional (UTN). En el marco de dicho proyecto se propone implementar NILM mediante *aprendizaje automático* (del inglés *machine learning*) para el análisis del

consumo de energía en los hogares argentinos, a través de la utilización de redes neuronales artificiales.

1. INTRODUCCIÓN

Para identificar el consumo eléctrico de los diferentes artefactos en una vivienda existen dos formas de realizar la medición: [1-2]: (1) mediante la utilización de medidores independientes para cada artefacto y/o algún equipo central que recolecte la información; (2) la aplicación de *Non-Intrusive Load Monitoring* (NILM) [3] o *Non-Intrusive (Appliance) Load Monitoring* (NIALM o NALM) [3-4], que podría traducirse como “*monitoreo de carga no invasivo*” o “*monitoreo de carga por métodos no invasivos*”. NILM es una técnica computacional que, a partir de una medición total de consumo de energía, logra identificar los artefactos eléctricos individuales que se encuentran consumiendo la misma [5]; medir cada artefacto conlleva a un método más exacto que NILM en términos de resultados obtenidos, pero las desventajas como costos elevados, múltiples configuraciones de sensores y complejidad en la instalación favorecen el uso del NILM [6]. Un enfoque comúnmente utilizado para implementar NILM involucra las siguientes etapas: (1) *adquisición de datos*; (2) *extracción de*

patrones; e (3) inferencia o aprendizaje automático [6].

El proyecto que se describe en este trabajo pretende abarcar las tres etapas. Para la primera parte, se está trabajando en una fase de prueba para la adquisición de datos y poder obtener muestras de diversos consumos en nuestra Facultad. La segunda etapa, que consiste en la extracción de patrones, ya ha sido implementada y ha producido los resultados esperados, descritos en un trabajo previo: [7]. La misma ha implicado identificar los datos de muestras de diversos artefactos individuales (que podrían ser ondas de voltaje y corriente, o potencia, como se observa en la Figura 1, la cual muestra las ondas de potencia instantánea de dos artefactos comunes: un lavarropas en la parte superior y una pava eléctrica en la parte inferior), con el objetivo de extraer métricas de potencia (potencia reactiva, potencia activa, potencia media, etc.), así como eventos de transición de estados (estados “encendido/apagado” u “ON/OFF”). Esta etapa tiene un impacto directo en siguiente fase de aprendizaje, pues permite obtener ejemplos de calidad para el entrenamiento de la técnica de aprendizaje automático. Si el conjunto de ejemplos no contiene buenos datos o datos de calidad, el aprendizaje posterior se verá afectado. Ante la falta de datos de muestreo locales, se ha decidido utilizar como punto de partida los datos proporcionados por el repositorio UK-DALE (su parte de baja frecuencia, con datos muestreados cada 6 segundos). El objetivo fue encontrar un algoritmo capaz de identificar los *ciclos de activación* (períodos durante los cuales los artefactos se encuentran consumiendo energía) de los distintos artefactos eléctricos medidos en forma individual, sin considerar ruidos, perturbaciones y señales de anomalía. Por

ejemplo, en la Figura 2 se puede apreciar un ciclo de activación de un lavarropas, en medio de dos grupos de interferencias, que deben ignorarse (en t_1 , entre t_2 y t_3 , y en t_8 y t_9); los retornos a cero también constituyen situaciones que deben ignorarse, pues pueden confundirse con el final de un ciclo de activación y el comienzo de otro nuevo (t_5 y t_6). La Figura 3 muestra señales reales de este tipo de anomalías.

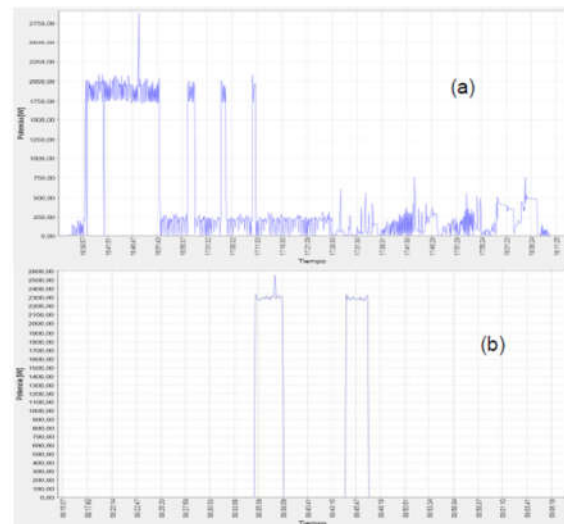


Figura 1: Consumo de dos artefactos eléctricos a través del tiempo, en baja frecuencia (6 segundos), usando datos de origen del repositorio UK-DALE¹. (a) Lavarropas. (b) Pava eléctrica.




Figura 2: Onda de consumo de ejemplo, mostrando posibles perturbaciones [7].

Para la correcta extracción de los ciclos de activación de los artefactos, el grupo de investigación desarrolló un algoritmo de detección, el cual fue implementado y validado con los datos del repositorio

¹ <http://jack-kelly.com/data/>

seleccionado, donde se parte de lecturas de potencia y tiempo de los artefactos (considerando baja frecuencia), y determina en tres pasos si una medición dada contiene (1) el inicio de un ciclo, (2) el final del mismo y (3) valores acordes entre inicio y fin. Es mediante la interacción de estas tres acciones que el algoritmo permite extraer el ciclo de activación completo de un artefacto.




Figura 3: Aspectos a tener en cuenta durante la detección de ciclos de activación (datos del repositorio UK-DALE). (a) Perturbaciones (heladera). (b) Retornos a cero (lavavajillas).

Diseñado el algoritmo, se procedió a la implementación y prueba del mismo. Para ello, primeramente, se cargaron los valores del repositorio UK-DALE en una base de datos MySQL, debido a que los datos originales se encontraban en archivos de texto plano. Una vez transferidos a la base de datos, los valores pueden buscarse con mayor facilidad, para estudiar las mediciones de un día determinado, por ejemplo. Mediante una aplicación Java, la cual implementa el algoritmo, es posible: (1) seleccionar un período para obtener la medición (por ahora, es posible seleccionar períodos equivalentes a un día completo, por lo que la granularidad es de un día); (2) especificar el artefacto a

evaluar para encontrar los ciclos de activación; y (3) configurar los parámetros del algoritmo. Una vez especificada esta información, es posible graficar la medición y los ciclos de activación detectados, para determinar visualmente si dichos ciclos de activación son correctos. Los ciclos identificados brindan información acerca de los mismos: (1) su potencia media; (2) su potencia máxima; y (3) su duración [7]. La Figura 4 muestra dicho gráfico, con tres ciclos detectados para el caso de un lavarropas.




Figura 4: Vista del gráfico que muestra los resultados del algoritmo.

Mediante esta introducción se ha descrito el trabajo realizado en el transcurso del primer año del proyecto de investigación, se pretende ahora comenzar la última etapa del proyecto, que consiste en desarrollar la fase de aprendizaje automático mediante la evaluación y selección de una arquitectura apropiada de red neuronal y la integración de lo implementado en las tres fases.

2. LÍNEAS DE INVESTIGACIÓN Y DESARROLLO

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 de energía eléctrica.

- Agentes y sistemas inteligentes.

3. RESULTADOS ESPERADOS

Tal como quedó expuesto, se lograron identificar los ciclos de activación de varios artefactos eléctricos y depurar la base de datos de muestras con el objetivo de contar con ejemplos consistentes para el entrenamiento de las herramientas de aprendizaje automático. La aplicación de aprendizaje automático busca el detectar el funcionamiento de cada artefacto eléctrico, con el objetivo a futuro de detección de distintas anomalías, como excesos injustificados de consumo o mal uso del artefacto.

Al contar con datos depurados, el tipo de aprendizaje que se pretende realizar será del tipo supervisado; esto significa que los datos deben encontrarse etiquetados. Se analizarán distintas estructuras de redes neuronales para el aprendizaje, pero se hará foco en: (1) *redes recurrentes* y (2) *redes autoencoder*. Las redes recurrentes trabajan con datos secuenciales (fundamental para los tipos de datos que se manejan) [8] y constituyen redes de *retro-propagación* (o del inglés, *backpropagation*). Esta retro-propagación le permite a la red generar y detectar patrones variantes en el tiempo. Dentro de las redes recurrentes, se analizará la *red Elman*, que trabaja con dos funciones de activación (*tansigmosoidal* en sus capas ocultas y una función lineal en su salida), lo que permite aproximar cualquier función (considerando el comportamiento discontinuo del funcionamiento de los artefactos) con cierta exactitud en base a la cantidad de neuronas en su capa oculta. Por otro lado, y buscando un tipo de aprendizaje relacionado con imágenes, se analizarán redes autoencoder, que pertenecen al conjunto de *redes convolucionales*, diseñadas para descubrir características de imágenes [9], por medio

de operaciones no lineales. En este tipo de estructura la comunicación es hacia delante, pero no todas las neuronas de una capa oculta reciben la información de todas las neuronas de la capa anterior, lo que conduce a reducir el número de capas y de operaciones entre neuronas.

Con el estudio, implementación y comparación de estas dos estructuras, se buscará determinar cuál es la óptima para dar solución al problema.

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 realizando su carrera de Doctorado en Ingeniería, con mención en Sistemas de Información (en la UTN Facultad Regional Santa Fe), otro ha finalizado recientemente su Doctorado en Ciencias de la Ingeniería, con mención Ingeniería Eléctrica (en la Universidad Nacional de Río Cuarto) y dos se encuentran desarrollando sus tesis para las Maestrías en Ingeniería de Software y Calidad de Software (en la UTN Facultad Regional San Francisco), quienes a su vez dictan la cátedra Inteligencia Artificial (Ingeniería en Sistemas de Información) en la UTN Facultad Regional San Francisco.

Se prevé la capacitación y formación de recursos humanos, a través de cursos de actualización y posgrado en el área de estudio; la transferencia de conocimiento y resultados; y la posibilidad de brindar charlas informativas del desarrollo e implementación del proyecto a distintos sectores de la industria interesados y cátedras afines a la investigación.

5. BIBLIOGRAFÍA

- [1] Dong, M., Meira, P. C., Xu, W. y Freitas, W. (2012). "An event window based load monitoring technique for smart meters". *IEEE transactions on smart grid*, 3(2), 787-796.
- [2] Ridi, A., Gisler, C. y Hennebert, J. (2014, Agosto). "A survey on intrusive load monitoring for appliance recognition". *Pattern Recognition (ICPR), 2014 22nd International Conference on* (pp. 3702-3707). IEEE.
- [3] Bernard, T. y Marx, M. (2016, Mayo). "Unsupervised learning algorithm using multiple electrical low and high frequency features for the task of load disaggregation". *Proceedings of the 3rd International Workshop on NILM*, Vancouver, BC, Canada (pp. 14-15).
- [4] Hart, G. W. (1992). "Nonintrusive appliance load monitoring". *Proceedings of the IEEE*, 80(12), 1870-1891.
- [5] Kelly, J. y Knottenbelt, W. (2015, Noviembre). "Neural nilm: Deep neural networks applied to energy disaggregation". *Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments* (pp. 55-64). ACM.
- [6] 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.
- [7] Cocconi, D., Yuan, R., Mulassano, M., Ferrero, N., Beltramone, M. y Biasco A. (2018). "Diseño de un algoritmo para la detección eficaz de ciclos de activación en la aplicación de monitoreo de carga por métodos no invasivos (NILM)" *6to Congreso Nacional de Ingeniería en Informática / Sistemas de Información, Universidad CAECE*. Mar del Plata, Buenos Aires, Argentina.
- [8] Contreras, W., Arichávala, M., y Jeréz, C. (2018). "Determinación de la presión máxima de compresión de un motor de encendido provocado basado en una red neuronal artificial recurrente". *Ingenius*.
- [9] Pusiol, P. D. (2014). "Redes Convolucionales en Compresión de Escenas". FAMAFA- UNC, Córdoba.