

DESAGREGACIÓN DE LA DEMANDA USANDO NON INTRUSIVE LOAD MONITORING TOOLKIT (NILMTK)

Andrés Arias¹, Enrique Personal^{1,2} y Antonio Parejo^{1,2}

¹ Escuela Politécnica Superior, Universidad de Sevilla, Sevilla.

² {epersonal, aparejo}@us.es

E-mail de correspondencia: andarisil@alum.us.es

RESUMEN

La desagregación no intrusiva de la demanda (o Non-Intrusive Load Monitoring, NILM) es una técnica computacional para la estimación del consumo individual de diversos dispositivos utilizando la lectura agregada de un solo medidor de energía (Smart Meter, SM). Este concepto ha tomado relevancia en los últimos años en el ámbito de las Smart Grids, al aportar una estimación de los hábitos de consumo de los clientes sin la necesidad de un despliegue masivo de instrumentación. Este trabajo aborda esta temática a través del uso práctico de una herramienta denominada NILM Toolkit (NILMTK) y la implementación de un nuevo dataset público con datos de energía del Aula 2.2 Bis de la Escuela Politécnica Superior de la Universidad de Sevilla.

INTRODUCCIÓN

Desde el año 2010, el número de publicaciones científicas referentes a la desagregación no intrusiva de la demanda se ha incrementado exponencialmente. Este interés se encuentra asociado directamente a los beneficios de esta técnica en el marco de las redes inteligentes de energía. Dentro de estas las aplicaciones, está la posibilidad de generar facturas de electricidad que muestren en detalle el consumo de los electrodomésticos utilizando solamente las lecturas de un SM (Figura 1).

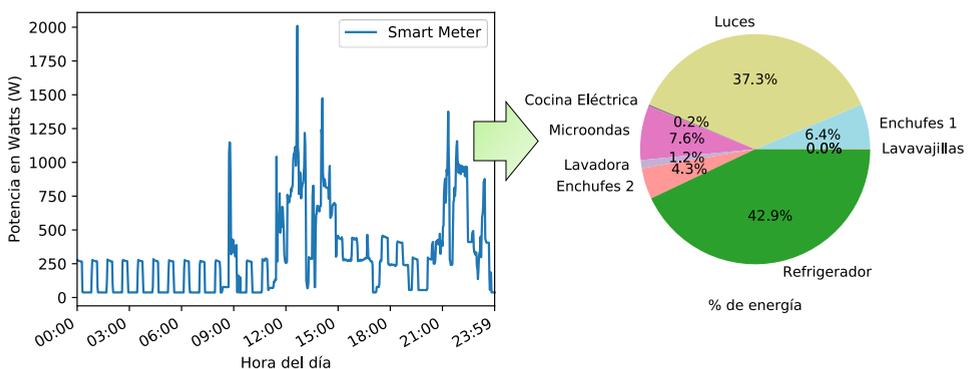


Figura 1. Ejemplo de desagregación de la demanda mediante un Smart Meter.

Fuente: elaboración propia.

Asimismo, existen aplicaciones de Energy Management System (EMS) en conjunto con NILM, las cuales pueden ser compatible con los programas de respuesta a la demanda o Demand Response (DR) de las compañías de electricidad. Por otro lado, algunos plantean la posibilidad de usar NILM para detectar averías en los dispositivos cuando se presenta un comportamiento anómalo en las mediciones desagregadas.

Es así como NILM se presenta como una valiosa herramienta para reducir el consumo de energía, tanto así que algunos afirman que es el “santo grial de la eficiencia energética”.

METODOLOGÍA E IMPLEMENTACIÓN

En este trabajo, un caso real de aplicación representa una problemática a resolver en el ámbito de la desagregación de la demanda a la cual se puede dar solución con la herramienta NILMTK. Para ello es importante definir una metodología en particular dado que NILMTK es mayormente usada en investigación para la comparación de algoritmos y particularmente no contempla un uso diferente a este. La metodología implementada utiliza el pipeline de NILMTK y se ha dividido en seis etapas: Nuevo Dataset, Análisis, Preprocesamiento, Entrenamiento, Validación y Desagregación (Figura 2).

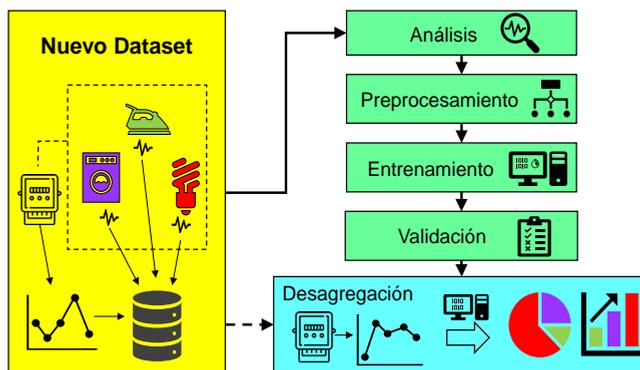


Figura 2. Esquema de la metodología de trabajo propuesta.

Fuente: elaboración propia.

El sistema eléctrico del Aula 2.2 Bis (Figura 3a) permite la adquisición y almacenamiento de variables eléctricas agregadas y desagregadas. Estos datos fueron recolectados entre el 24 de febrero y el 6 de marzo de 2020. Esto permite la creación de un nuevo dataset denominado Dataset de la Escuela Politécnica Superior (DEPS) el cual es analizado usando las funciones de NILMTK lo que permite, por ejemplo, visualizar los datos de potencia en un determinado periodo (Figura 3b) u obtener estadísticas de energía del dataset.

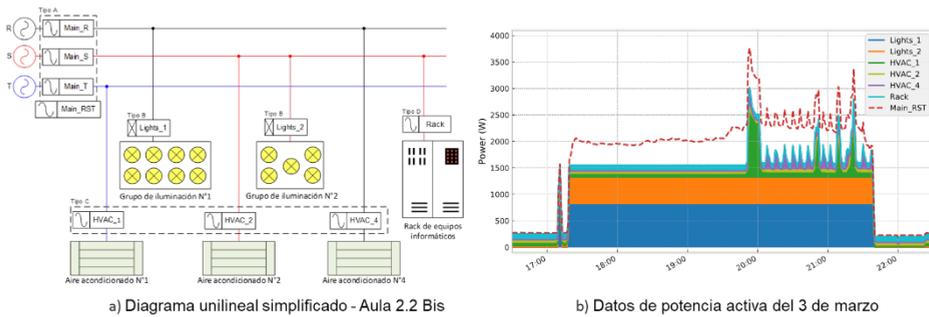


Figura 3. Diagrama unilineal del sistema y datos de potencia activa.

Fuente: elaboración propia.

Posteriormente, en la etapa de preprocesamiento se toman decisiones en línea con los análisis realizados, con el objetivo de preparar correctamente los datos para del entrenamiento de los modelos de desagregación. Básicamente, el entrenamiento de un modelo consiste en enseñarle a reconocer por separado las características de los dispositivos para luego identificarlos dentro de una señal agregada. El entrenamiento contempla el uso de los algoritmos Combinatorial Optimization (CO) y Factorial Hidden Markov Model (FHMM).

RESULTADOS Y DISCUSIÓN

Los modelos entrenados permiten la generación de 42 escenarios de desagregación considerando 2 algoritmos, 3 técnicas de muestreo (primer dato, promedio y mediana) y 7 periodos de muestreo distintos: 10s, 30s, 60s, 5min, 10min, 15min y 30min. Estos escenarios son comparados mediante el uso de métricas ampliamente utilizadas en NILM, lo que permite evaluar su desempeño y determinar cuál de ellos se adapta a las necesidades del problema estudiado.

Los resultados muestran una superioridad del algoritmo FHMM sobre CO en la mayoría de las instancias, especialmente para los escenarios de 10 o más minutos. Desde el punto de vista de la adquisición de datos para la desagregación, se busca optimizar los recursos por lo que una tasa de muestreo baja es atractiva para una implementación. Dado esto y en vista de los buenos resultados obtenidos, se propone la elección del modelo FHMM entrenado con datos de potencia correspondientes a la mediana cada 30 minutos. Finalmente, este modelo es implementado sobre un set de pruebas mostrando los resultados de la desagregación del Aula en un panel interactivo el cual es implementado en una página web.

CONCLUSIONES

La desagregación de la demanda se presenta como una técnica innovadora capaz de dar solución, o al menos brindar ayuda para resolver el problema de la eficiencia energética. En este sentido, los avances de la comunidad académica y del sector industrial apuntan en desarrollar nuevos algoritmos y métodos de implementación para el avance y desarrollo de esta técnica.

La metodología propuesta en este trabajo permitió utilizar la mayoría de las funcionalidades de NILMK e integrar características adicionales gracias a que se la herramienta se encuentra programada en Python.

Una de las etapas más importantes del proceso es el análisis del dataset, ya que en ella se concentra gran parte del esfuerzo en determinar qué datos serán utilizados para el entrenamiento de modelos y posterior desagregación.

REPOSITORIO

Todo el desarrollo e implementación de código de programación de este trabajo se encuentra en el siguiente repositorio de GitHub:

https://ariassilva.github.io/DEPS_NILM_Dataset/

REFERENCIAS BIBLIOGRÁFICAS

- Batra, N., Kelly, J., Parson, O., Dutta, H., Knottenbelt, W., Rogers, A., Singh, A., & Srivastava, M.** (2014). NILMTK: an open source toolkit for non-intrusive load monitoring. En *5th International Conference on Future Energy Systems (ACM e-Energy)*, 265–276. <https://doi.org/10.1145/2602044.2602051>
- Hart, G. W.** (1992). Nonintrusive appliance load monitoring. *Proceedings of the IEEE*, 80(12), 1870-1891. <https://doi.org/10.1109/5.192069>
- Zoha, A. Gluhak, A., Imran, M. A., & Rajasegarar, S.** (2012). Non-Intrusive Load Monitoring Approaches for Disaggregated Energy Sensing: A Survey. *Sensors - Open Access Journal*, 12(12), 16838-16866. <https://doi.org/10.3390/s121216838>