

# MODELO BASADO EN APRENDIZAJE AUTOMÁTICO DE CONSUMO DE ELECTRODOMÉSTICOS A PARTIR DE MONITOREO NO INTRUSIVO

Juan L. Barberia, Juan F. Fernandez Biancardi, Giancarlo Lottero, Sebastián Esangui, Lorenzo Licata Caruso y Walter E. Legnani

*Centro de procesamiento de señales e imágenes, Universidad Tecnológica Nacional, Buenos Aires, Argentina,*  
<https://www.frba.utn.edu.ar/cpsi/>

**Resumen:** El monitoreo de carga no intrusivo es un conjunto de técnicas cuyo objetivo es la identificación de los electrodomésticos utilizados en una vivienda partiendo de la señal de consumo energético agregada que producen al utilizarse. La base de datos empleada es la denominada Reference Energy Disaggregation Data Set (REDD) la cual es de acceso gratuito y contiene información detallada del consumo eléctrico de artefactos de varios hogares. El presente trabajo tiene como objetivo utilizar herramientas de Machine Learning supervisado para lograr una clasificación satisfactoria de electrodomésticos del mismo tipo presentes en diferentes viviendas, partiendo de señales de consumo eléctrico, medidas en circuitos individuales. Los resultados muestran obtenidos una precisión lo suficientemente elevada como para alentar la continuación de esta línea de estudio.

**Palabras clave:** *monitoreo no intrusivo, aprendizaje automático, transiciones entre patrones ordinales, entropía, complejidad.*

2000 AMS Subject Classification: 00A69 - 68Q32

## 1. INTRODUCCIÓN

El desarrollo del monitoreo de carga no intrusivo o NILM [3], por sus siglas en inglés Non Intrusive Load Monitoring, está ligado a la sustentabilidad y optimización del consumo energético en viviendas ya que provee información de utilidad para la toma de decisiones. [10], [4], [8].

Aquino y colaboradores [1] han realizado estudios sobre la clasificación de electrodomésticos a partir de su consumo utilizando cuantificadores de la teoría de la información, como la entropía y la complejidad estadística. Haciendo uso del plano de complejidad-entropía, se puede observar claramente que los electrodomésticos pertenecientes a alguna clase en particular se agrupan en una parte del plano, quedando diferenciados de las otras categorías.

El algoritmo de clasificación utilizado en el presente trabajo es el de Máquinas de Soporte Vectorial, por sus siglas en inglés SVM, que es un clasificador lineal y será explicado con mas detalle en la sección 2.2

La base de datos utilizada es REDD. Con la adecuada identificación de los diferentes electrodomésticos en uso en los hogares se espera mejorar las futuras generaciones de medidores de consumo/producción de energía eléctrica que estarán integrados en los nuevos paradigmas de producción distribuida.

## 2. METODOLOGÍA Y FUENTE DE DATOS

La base de datos usada corresponde a la base de datos de acceso público REDD [5]. La cual contiene información acerca de los consumos eléctricos dentro de seis domicilios durante un período de dos meses. Separados de acuerdo al circuito/equipamiento individual que corresponda tales como como heladeras, luminarias, hornos o estufas, lavavajillas, lavarropas, microondas, y diversidad de artefactos que pueden hallarse conectados a un tomacorriente; como también una medición del consumo general de la vivienda. La base de datos posee registros obtenidos en baja y alta frecuencia, en el presente trabajo se utilizó el conjunto de datos en baja frecuencia, con una tasa de muestreo de 3 segundos por circuito/equipamiento y de 1 segundo para el consumo general.

La base de datos fue preprocesada, obteniéndose sub-muestras del ciclo de funcionamiento de cada electrodoméstico. Este conjunto luego fue separado en un 80 % para el entrenamiento del algoritmo de clasificación dejando el 20 % restante para la validación y tests del mismo, el cual se mostrará en la sección de resultados.

## 2.1. PATRONES ORDINALES Y TRANSICIONES

Los patrones ordinales surgen como una medida de complejidad de una determinada sección de una serie de tiempo con respecto a su alrededor. Esta noción fue introducida por [2], en donde calculando la entropía de permutación de la distribución de patrones ordinales es posible caracterizar sistemas dinámicos caóticos de forma similar a lo que se hace con los exponentes de Lyapunov. La interpretación que se le da a la entropía de permutación es la de caracterizar el tipo de sistema dinámico observado. Teniendo un bajo nivel de entropía significa que el sistema es altamente predecible, mientras que valores elevados de entropía corresponden a altos niveles de variabilidad. En otro sentido, para determinar si una señal es altamente variable o simplemente afectada por un ruido gaussiano se la puede comparar frente a este mismo ruido. Tomando la entropía cruzada entre las distribuciones de probabilidades de la señal y el ruido, se calcula la divergencia de Jensen-Shannon que mide la diferencia entre ellas. Esto permite definir un nuevo parámetro informacional que es la complejidad estadística. Para mayor información remitirse a [6].

La clasificación a través del uso de los patrones ordinales de una señal temporal se basa en describir a esta señal a través de funciones de probabilidad de su composición secuencial y progresión a través del tiempo.

La transición entre patrones ordinales, es una alternativa usada para mejorar la caracterización de las señales provenientes de sistemas complejos. En el caso de las transiciones entre patrones ordinales, se puede obtener una estimación del exponente de Hurst para analizar la dependencia de largo alcance y la autocorrelación de la señal [7].

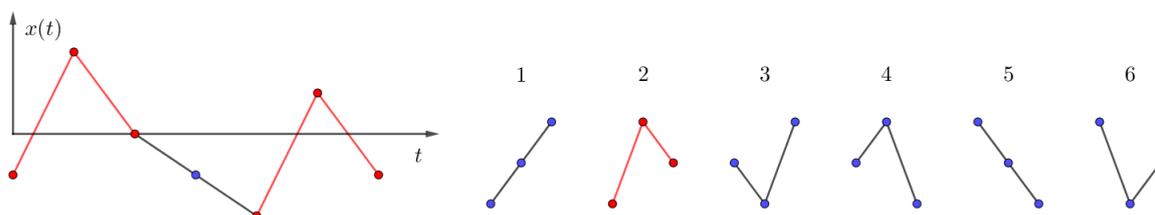


Figura 1: Ejemplo de señal temporal caracterizada por la presencia de diferentes tipos de patrones (izquierda) en función de su aparición. En la imagen de la derecha se destaca la presencia del patrón número 2 presente en  $x(t)$

## 2.2. MÁQUINA DE SOPORTE VECTORIAL

La maquina de soporte vectorial es un clasificador lineal que busca maximizar el margen entre diferentes clases. Esta maximización del margen permite obtener una mayor generalización del modelo de clasificación ya que disminuye la dimensión de Vapnik-Chervonenski. [9]

Para poder tratar espacios no lineales, se puede aplicar un mapeo de las características a un espacio de mayor dimensión, espacio reproducible de Kernel de Hilbert. La separación de clases en ese espacio es lineal pero en el espacio original es no lineal.

En este trabajo se utilizó un kernel de base radial sobre los vectores soporte para el algoritmo de SVM. Mas precisamente se empleó un kernel gaussiano y se varió el parámetro de escala hasta obtener el mayor valor de precisión sobre el conjunto de entrenamiento.

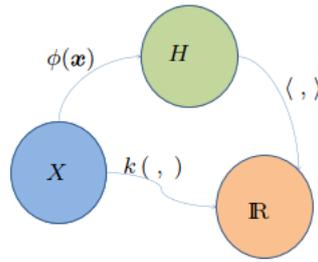


Figura 2: Mapeo del conjunto original de datos  $X$  hacia el espacio reproducible de Hilbert  $H$ , y vinculación de la función de kernel  $k$  con el dominio  $\mathbb{R}$  de la función de clasificación; Aquí  $\langle ., . \rangle$  corresponde al producto escalar.

### 2.3. ESPACIO DE CARACTERÍSTICAS

Con los conceptos introducidos en la presente sección se construyó el espacio de características empleado en el algoritmo de SVM. De esta manera este estuvo constituido por los siguientes parámetros: entropía de permutación de Shannon, complejidad estadística, probabilidad de transición entre patrones ordinales, entropía de permutación ponderada, valores de cruce de la señal por su valor medio. Este último parámetro se incorporó para dar cuentas de la fluctuación de la señal en el tiempo.

### 3. RESULTADOS

Las clases de electrodomésticos de la base original se redujeron a solo 6, a saber: aire acondicionado, anafe, calefactor, heladera, horno y microondas. La red de las transiciones entre patrones ordinales de dos electrodomésticos (microondas y horno) se muestran en la Figura 3, en esta se destaca la diferencia en la geometría de las mismas. En la Figura 4 (derecha) se halla representada a modo de ejemplo el área bajo la curva de operación del clasificador para el caso de la clase correspondiente a la heladera. En lado izquierdo de la misma figura se muestra la matriz de confusión para las seis clases de electrodomésticos empleadas en la presente investigación. En la cual se obtuvo una precisión del 92.2 % sobre el conjunto de datos de test.

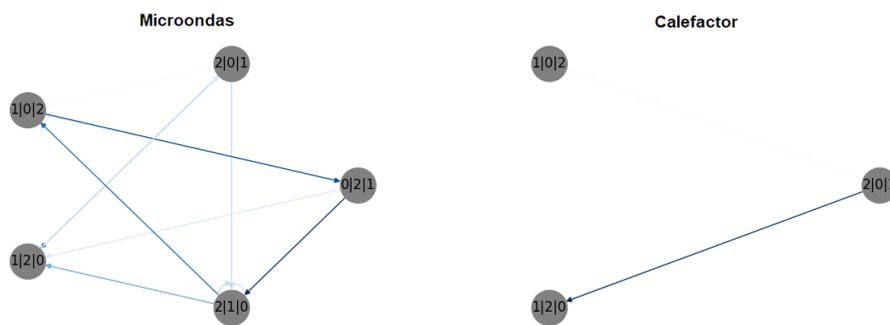


Figura 3: Diferencias encontradas entre los diferente tipos de electrodomésticos y sus correspondientes patrones de transición.

### 4. CONCLUSIONES

El objetivo propuesto al inicio del trabajo ha sido cumplido si se considera valor de la precisión en la clasificación realizada que resultó ser del 92.2 %. Este hecho estaría mostrando que se puede capturar la estructura característica de los consumos de los diferentes electrodomésticos en base al conjunto de características con las que se entrenó el algoritmo de SVM con el kernel correspondiente empleado. La diferencias

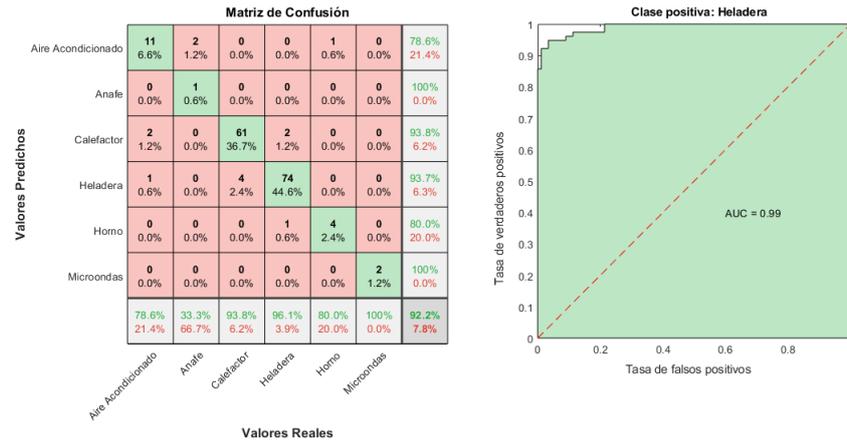


Figura 4: Resultados obtenidos en la clasificación de electrodomésticos: a la izquierda se encuentra la matriz de la confusión, a la derecha se muestra a modo ilustrativo una de las curvas de operación del clasificador, correspondiente a la clase 'heladera'.

observadas entre la distribución de la transición de patrones ordinales puede brindar información adicional para mejorar los metodología de adquisición y procesamiento de señales existentes de NILM. En futuros trabajos se investigará la aplicación de esta técnica de clasificación para discriminar los consumos en el punto común de conexión (medidor) domiciliarios.

## 5. REFERENCIAS

- [1] A. AQUINO, H. RAMOS, A. FRERY, L. VIANA, P. LEONARDO, S. TAMER AND R. ROSSO, *Characterization of electric load with information theory quantifiers*, *Physica A: Statistical Mechanics and its Applications*, 465, 277–284, Elsevier, 2017
- [2] C. BANDT AND B. POMPE, *Permutation entropy: a natural complexity measure for time series*, *Physical review letters*, 174102. 2002
- [3] X. FANG, S. MISRA, G. XUE AND D. YANG, *Smart grid - The new and improved power grid: A survey*, *Commun. Surv. Tutor.* 14 (4),944–980. 2012
- [4] H. KIM, M. MARWAH, M. ARLITT, G. LYON AND J. HAN, *Unsupervised disaggregation of low frequency power measurements*, *SIAM Conference on Data Mining*, 747–758. 2011
- [5] J. Z. KOLTER, M. AND JOHNSON, *REDD: A public data set for energy disaggregation research*, *Workshop on data mining applications in sustainability (SIGKDD)*, San Diego, CA, 25, 59–62, 2011
- [6] T. MARTIN, MARÍA, A. PLASTINO, ÁNGEL AND O. ROSSO, *Physica A: Statistical Mechanics and its Applications*, Generalized statistical complexity Geometrical and analytical properties, 2, 439–462, 369. Elsevier, 2006.
- [7] A. PESSA, AND H. RIBEIRO, *CHARACTERIZING STOCHASTIC TIME SERIES WITH ORDINAL NETWORKS*, *Physical Review E*, 042304. 2019
- [8] H. SHAO, M. MARWAH AND N. RAMAKRISHNAN, *A temporal motif mining approach to unsupervised energy disaggregation: Applications to residential and commercial buildings*, *AAAI Conference on Artificial Intelligence*, 1327–1333. 2013
- [9] T. HASTIE, R. TIBSHIRANI, J. FRIEDMAN AND H. FRIEDMAN, *The elements of statistical learning: data mining, inference, and prediction*, Vol. 2, pp. 1-758. New York: springer. 2009
- [10] M. WYTOCK AND J.Z. KOLTER, *Contextually supervised source separation with application to energy disaggregation*, *AAAI Conference on Artificial Intelligence*, 486–492, 2014.