

Intelligent Electrical Pattern Recognition of Appliances Consumption for Home Energy Management using High Resolution Measurement

F. Ulloa-Vásquez, L. García-Santander, D. Carrizo, V. Heredia-Figueroa

Abstract—For an efficient energy management by residential users, monitoring and control of connected household appliances is required. If the consumption pattern of each of these devices is identified, then the management will be more efficient, reducing both the billing and the CO₂ emissions. This paper proposes a model for the recognition of energy consumption patterns in household appliances, based on the capture of electrical parameters in connected appliances, through Smart Socket with an Intrusive Load Monitoring approach. The data acquisition system corresponds to an-Internet of Things (IoT) platform that uses Automatic Meter Reading devices, connected to a IoT-gateway via Wi-Fi to send data to an application on the web. For the recognition of the patterns, machine learning techniques are used. Accuracy results on pattern identification are obtained about 91% after applying a backpropagation method in an Artificial Neural Network in time basis. Through this work, the prediction of consumer categories in household appliances, with high levels of reliability and under multiple operating states, is reached. These results enhance the efficient management of energy in a Smart Home and Smart Cities environment.

Index Terms—Automatic Meter Reading (AMR), Home Energy Management Systems (HEMS), Intrusive Load Monitoring (ILM), Pattern Recognition, Smart Socket.

I. INTRODUCCIÓN

El cambio climático que está sufriendo aceleradamente el planeta, ha llevado a que cada país proponga estrategias que conlleven un uso eficiente de los recursos energéticos. El estado chileno ha fijado una política energética al año 2050, que establece como uno de sus pilares, la eficiencia energética. En este contexto, el consumidor residencial ha tomado un rol activo para gestionar su uso de energía eléctrica y con ello influir en el comportamiento de su patrón de consumo. Este reconocimiento facilita el uso eficiente tanto para el consumidor residencial como para la empresa distribuidora de energía eléctrica.

F. Ulloa-Vásquez, Programa de Investigación en Radiocomunicación Digital (PIRD), Universidad Tecnológica Metropolitana (UTEM). Virginito Arias 1369, Ñuñoa, Santiago de Chile. fulloa@utem.cl.

L. García Santander, Departamento de Ingeniería Eléctrica, Universidad de Concepción, Concepción, Chile. luis.garcia@udec.cl.

D. Carrizo, Departamento de Ciencias de la Computación, Universidad de Atacama, Copiapó, Chile. dante.carrizo@uda.cl.

V. Heredia-Figueroa, Programa de Investigación en Radiocomunicación Digital (PIRD), Universidad Tecnológica Metropolitana (UTEM). Virginito Arias 1369, Ñuñoa, Santiago de Chile. victor.herediaf@utem.cl.

Para la empresa distribuidora el conocer el perfil de comportamiento, permite que se maximice el uso de la capacidad de su infraestructura obteniendo una reducción en las emisiones y contribuyendo al desarrollo sostenible. Por su parte para el consumidor residencial, permite el uso responsable de la energía, obteniendo una reducción en su facturación mensual. Actualmente el desarrollo de Sistemas de Gestión (Energy Management System EMS) para alcanzar la eficiencia energética en las zonas con alta concentración de cargas públicas, empresariales y residenciales, es considerado un problema de interés en las Redes Inteligentes o Smart Grid. El uso de Home Energy Management System (HEMS) contribuye a gestionar la demanda, especialmente durante las horas de máximo consumo, esto mediante programas de Respuesta a la Demanda (Demand Response DR). Así, los usuarios podrán participar en el control de la demanda en tiempo real, adaptando el consumo de tal forma que se permita reducir la demanda durante las horas pico y adecuarlas inteligentemente a las horas de poca actividad.

En el presente artículo se discuten trabajos relacionados con esta investigación, principalmente sobre Medidores Automáticos No intrusivos (medidores automáticos de consumo) e Intrusivos (tomas de corrientes inteligentes). Para esto, se diseñó una toma de corriente inteligente de bajo consumo, alta precisión y bajo costo. Luego se llevó a cabo una campaña de medición de consumo eléctrico de 22 artefactos diferentes en 20 hogares durante 90 días. Con los datos obtenidos se implementó una red neuronal artificial que permitió la caracterización y huella digital de consumo del artefacto y su diferenciación de otros dispositivos conectados simultáneamente a la red eléctrica.

El resto del documento está organizado de la siguiente manera: la Sección II presenta los trabajos relacionados con este estudio; la Sección III describe la metodología utilizada y desarrollo del sistema propuesto; la Sección IV, expone el desarrollo experimental y resultados obtenidos; la Sección V discute los resultados; y finalmente, la Sección VI exhibe las conclusiones del trabajo.

II. TRABAJOS RELACIONADOS

En esta sección se muestran y discuten algunos trabajos relacionados con el tema de la gestión eficiente de la energía en un entorno smart home y ciudades inteligentes. Se destacan sus principales diferencias entre dispositivos de medición propuestos y sus relaciones, su velocidad de muestreo, tipo de

operación y resolución en la medida temporal.

El estado de la técnica muestra diferentes alternativas para la obtención de la “huella digital de consumo” de los artefactos eléctricos, elemento importante que motiva el desarrollo de este trabajo, de tal manera de lograr proponer un dispositivo intrusivo Smart Socket (SS) que alcance mejoras en la eficiencia del reconocimiento del perfil del artefacto y mejor uso de la energía del Hogar [1]. Los HEMS, utilizan técnicas de monitoreo que generalmente se clasifican en Monitoreo de Carga No Intrusivos (Non Intrusive Load Monitoring NILM) y Monitoreo de Carga Intrusivos (Intrusive Load Monitoring ILM) [2]. Las características que diferencian estas dos técnicas es que NILM sólo utiliza un punto de monitoreo que generalmente está ubicado en la entrada de la alimentación principal del sistema eléctrico del hogar (conocidos como Smart Meter), mientras que ILM utiliza dispositivos sensores en cada una de las tomas de corriente (Smart Socket; Smart Plug SP) de todas o de principales cargas conectadas [3].

Generalmente los datos capturados del consumo de los artefactos se envían por internet y se almacenan en una plataforma web disponible en la nube. Estos datos en su mayoría corresponden a la potencia activa demandada por los artefactos [4], los cuales se procesan en ambiente Matlab® aplicando por ejemplo el algoritmo de Multi Layer Back-Propagation Neuronal Network (MLBPNN) que permite detectar el perfil de potencia real consumida por cada dispositivo eléctrico [5], así entonces se propone el concepto de huella digital del consumo del artefacto [6]. Por otra parte, los sistemas NILM tienen la ventaja de no intervenir el circuito del hogar con dispositivos costosos de monitoreo [7]. En cambio, los sistemas ILM, al tener sensores en diferentes cargas del circuito, brinda detalles más precisos sobre el consumo y alarmas referentes a cada electrodoméstico [8], pudiendo dar factibilidad de monitorear dispositivos de muy baja potencia y diferenciar entre un consumo variable y el consumo entre un conjunto de dispositivos [9].

Una red de sensores de SS está diseñada para su uso en entornos laborales y domésticos como un dispositivo, el cual es capaz de identificar el electrodoméstico en función del comportamiento de los patrones actuales consumidos por el artefacto eléctrico [10]. Los nodos se comunican entre sí utilizando la arquitectura inalámbrica Wi-Fi, PLC o ZigBee existente del entorno. La integración perfecta de la red de sensores es importante para tener éxito en el ámbito de la computación ubicua. Se discuten las arquitecturas de hardware y software de los sistemas que analizan dispositivos de prueba y se explican los patrones de consumo y perfiles actuales de electrodomésticos [11]. De esta manera, se presenta una posible hipótesis de este comportamiento y se explica el uso del algoritmo clasificador que no necesita entrenamiento, pero solo una base de datos actualizable dinámicamente, creando así la necesidad de una base de datos en la nube conectada a todos los servidores domésticos. Las implementaciones del sistema y la descripción de los protocolos desarrollados para los controles del dispositivo también se comparan en los trabajos estudiados [12].

La identificación de patrones de artefactos se centra en la

desagregación de energía y el reconocimiento de dispositivos. En [13] y [14] se muestra el desarrollo de un sistema inteligente que analiza el uso de los dispositivos para extraer los patrones de comportamiento de los usuarios en un entorno doméstico inteligente. Por otra parte en [14] y [15], se busca optimizar el costo de la electricidad, donde los usuarios pueden recibir una advertencia del consumo excesivo de los aparatos conectado al sistema eléctrico del hogar.

En [16] y [17] los autores adoptan un sistema de medición distribuida de tomas de corrientes inteligentes, diseñando un algoritmo basado en ANN (Artificial Neural Network) que explota datos de medición de baja frecuencia con un consumo de energía cada dos minutos. En los trabajos [18], [19] y [20] se utiliza un algoritmo basado en lógica difusa que, mediante la activación del cálculo de parámetros tales como potencia máxima, potencia media y duración del ciclo, obtienen un resultado para la función de pertenencia, logrando la identificación del artefacto mediante grados de verdad. Sin embargo, los trabajos de investigación relacionados al reconocimiento automático de dispositivos eléctricos descritos por [21] y [22], realizan el muestreo en el orden de los 15 a 10 minutos, puesto que su objetivo es determinar el consumo energético de acuerdo a los sistemas de facturación.

También podemos mencionar que las publicaciones científicas sobre enfoques de NILM superan en número a las de ILM [23], dado que el enfoque NILM demuestra ser mucho más antiguo como los Medidores Mecánicos que ya casi cumplen un siglo de uso [24], [25]. Por otra parte, dado que los NILM (Smart Meter con precios de 300 a 400 USD) se basan en la utilización de un solo sensor, la instalación del sistema de detección es sencilla y la adquisición de datos es de menor calidad ya que solo podemos monitorear el consumo general en el hogar [26],[27]. El reconocimiento de aparatos que utiliza este tipo de enfoque generalmente adolece de precisiones debido al problema inherente de la suma de las señales de consumo de diferentes artefactos [28],[29]. Por otra parte, con el medidor ILM (SS, SP, precio entre 20 y 30 USD) la medición se basa en la utilización de múltiples sensores al interior del hogar, disponiendo de un mayor nivel de detalle y resolución en los datos de consumo, lo que facilita la identificación del artefacto eléctrico [30].

En este trabajo, la propuesta del Sistema Smart Socket ILM (Fig. 3), para monitorear, detectar y reconocer las principales cargas del hogar, utilizando medición automática (Automatic Meter Reading - AMR) se logra alcanzar una tasa de muestreo del orden de 1/20 Hz, superior a los trabajos [28], [29], [30] y con una resolución que permite no solo la diferenciación de cada artefacto eléctrico, sino que también el accionamiento de alarmas, encendido y apagado frente a un exceso de corriente (>16 Amperes) o sobre tensión (>230 Volts), habilitando la reconexión remota por el usuario una vez revisada la alarma. Por último, el algoritmo de aprendizaje de máquina logra discriminar con gran eficiencia a cada uno de los dispositivos con una velocidad de cálculo reducida, enviando información en tiempo real al usuario y determinando el consumo eléctrico del hogar y de cada uno de sus artefactos.

III. METODOLOGÍA Y DESARROLLO DEL SISTEMA

La Fig.1 muestra el diagrama esquemático que describe de manera breve cada una de las etapas de la metodología implementada en este trabajo.



Fig. 1. Descripción de la metodología utilizada.

A. Fase (A)

Se diseña un módulo de medición corriente/voltaje con comunicación inalámbrica Internet Protocol (IP). Se establecen rangos de valores máximos para voltaje y corriente. Finalmente, se configura un sistema de protección para sobrecargas.

B. Fase (B)

Se registran medidas de los 22 artefactos más comunes del hogar, medidos en 20 hogares diferentes, con tiempo de muestreo de 20 segundos y con ciclos de trabajo que dependen de la operación del artefacto.

C. Fase (C)

Contempla la implementación de una red neuronal con un marco jerárquico de sinapsis en una topología de avance, donde todos los nodos de una capa se vinculan de manera unidireccional para identificar características no lineales.

D. Fase (D)

Los datos son enviados a la nube para realizar las operaciones necesarias para generar valores representativos de cada uno de los artefactos eléctricos a comparar.

E. Fase (E)

Se crea un modelo identificador de matriz de huella digital de consumo para cada uno de los artefactos, generando un mapa de consumo de los artefactos eléctricos conectados en el hogar. Se crean submatrices para el testeo de los errores encontrados y validación del modelo.

En el contexto del desarrollo del Proyecto ITCity ELAC T10-0643–Eranet 2017-2020 Conicyt, “An ICT platform for sustainable energy ecosystem in Smart cities”, ejecutado por las instituciones Univ. Federal de Santa Catarina-Brasil, Inst. de Física Energética de Letonia, Univ. de Bucarest, Univ. de Concepción, Univ. de Atacama y Univ. Tec. Metropolitana, se diseñó un sistema que permite la adquisición de datos de una red de equipos de medición inteligente en cada toma de corriente, denominados Smart Sockets (SS). Este diseño corresponde a un módulo de medición Corriente-Voltaje con comunicación inalámbrica como un complemento inteligente con capacidad máxima de 15 (A) (ver Fig. 2a y Fig. 2b).

El modelo propuesto tiene la flexibilidad de la portabilidad del dispositivo a diferentes tomas de corrientes dentro del entorno de cobertura desplegado y para poder cambiar la identidad del dispositivo en la interfaz de usuario desde un Smartphone. El SS incluye una interfaz de comunicación, un sensor de corriente-voltaje, una unidad MCU (unidad de microcontrolador) y un circuito de conmutación.

La funcionalidad de estos SS es la siguiente:

- Medir el voltaje y la corriente instantánea que están presentes en el dispositivo conectado.
- Calcular la potencia instantánea demandada por el dispositivo conectado.
- Calcular la energía consumida por el dispositivo conectado.
- Ejecutar el algoritmo de solicitud de comunicación para transmitir el consumo de energía y tomar la decisión de encender/apagar por parte del Coordinador del dispositivo SS.

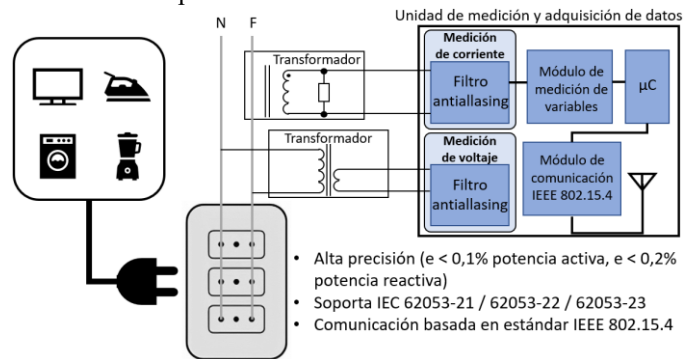


Fig. 2a. Arquitectura de un Smart Socket.



Fig. 2b. Circuito impreso de Smart Socket implementado.

Como se muestra en la Fig. 3, la medición del consumo se obtiene a través de un sensor de corriente y un sensor de voltaje, además de obtener la diferencia entre los pasos por cero de estas dos señales y calcular correctamente las potencias requeridas por las cargas (Activa, Reactiva y Aparente). La obtención de la señal de corriente se logra mediante un sensor no invasivo y la detección de la señal de voltaje se logra a través de un transformador.

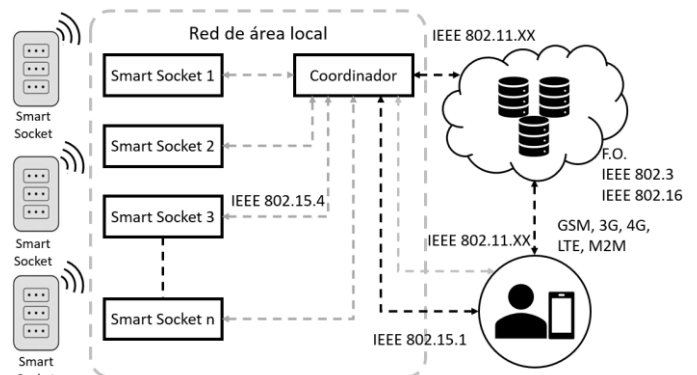


Fig. 3. Sistema Smart Socket ILM.

El desarrollo de este dispositivo permite tanto el control ON/OFF como el monitoreo de los distintos parámetros eléctricos (voltaje, corriente, potencia activa y reactiva, factor de potencia, frecuencia, entre otros) [8]. Los SS son conectados mediante WiFi/IEEE 802.11 al Access Point (AP), el cual funciona como Gateway-IoT que está encargado de enviar la información al servicio de la nube por medio de protocolos de comunicación ofrecidos por el Proveedor de Servicios de Internet (Internet Service Provider ISP). Los datos son presentados por medio de una aplicación Web Dashboard, la cual permite su extracción y uso para el entrenamiento y testeo de la red neuronal.

Dada la necesidad de un algoritmo liviano y de fácil implementación para un circuito integrado económico y de bajo consumo eléctrico, es que se eligió utilizar una red neuronal de percepción multicapa con algoritmo de propagación recursivo, llamado MLBPNN [10]. Este es un modelo supervisado conocido, utilizado en este trabajo debido a su simplicidad y convergencia garantizada. Estas características permiten su implementación futura incorporada en un paquete tecnológico de forma rápida y de bajo costo. En este trabajo, la red general del perceptrón multicapa, proporciona un algoritmo de aprendizaje automático con la tarea de clasificación de dispositivos. El modelo analítico es una red hetero-asociativa (perceptrón multicapa, MLP), donde todas las entradas conectadas al entorno externo son distintas de la salida que expresa la respuesta del sistema. Para este trabajo, se considera como entrada un vector de curva de potencia activa de la carga eléctrica, y como salida el reconocimiento del electrodoméstico conectado.

Los elementos de la red combinan un marco jerárquico de sinapsis en una topología de avance, donde todos los nodos de una capa se vinculan de manera unidireccional a los de la siguiente capa, para crear la posibilidad de identificar características no lineales. La capacidad para detectar relaciones no lineales, sin definir una expresión formal que no requiere una hipótesis "a priori" sobre el comportamiento de las variables, depende esencialmente del número de nodos, el número de capas, la función de transferencia de cada nodo y los factores de pesos de las conexiones.

La ecuación (1) representa la función de optimización para encontrar el mínimo error entre el patrón de consumo y los datos medidos por el SS.

$$\min \sum_{p=1}^{\infty} E_p(x) \quad (1)$$

donde E_p representa una medida del error relacionado con el patrón p (subconjunto) del conjunto de entrenamiento. Este error estima la brecha entre la salida dada en el conjunto de entrenamiento y la salida predicha por la red. El algoritmo de propagación recursivo es un método iterativo, una versión heurística del método de gradiente, comúnmente aplicado en redes de múltiples capas debido a sus altos rendimientos en términos de tiempo y precisión. La interacción que define la propagación recursiva está dada por (2):

$$w^{k+1} = w^k - a \nabla E_{p(k)}(w^k) + \eta (w^k - w^{k-1}) \quad (2)$$

Donde:

- $\nabla E_{p(k)}(w^k)$ es el gradiente de la función de error en el vector de corriente w^k de pesos;
- α (velocidad de aprendizaje), escalar que define el paso a lo largo de la dirección anti-gradiente $d^k = \nabla E(w^k)$, utilizando en cada paso solo el patrón actual de entradas y salidas $(x^{p(k)}, y^{p(k)})$;
- El escalar $\eta > 0$ (impulso), ejecuta una elección adaptativa del paso o modifica la dirección de la investigación para asegurar la convergencia del algoritmo.

El entrenamiento continuo de una red neuronal apunta a hacerlo funcionar siempre mejor, pero eventualmente llega a un punto donde el progreso hacia adelante es demasiado lento para ser práctico. Además, el sobreentrenamiento es inofensivo, porque puede llevar a un ajuste excesivo. Esto ocurre cuando la función de mapeo resultante del proceso de entrenamiento, se ajusta demasiado bien al patrón de consumo, perdiendo la capacidad de procesar nuevos datos.

IV. DESARROLLO EXPERIMENTAL

A continuación, se destacan los pasos ejecutados para el desarrollo experimental.

A. Data Set

Para este estudio, se diseña e implementa un método de estadísticas multivariadas e inteligencia computacional, con el objetivo de identificar artefactos electrodomésticos conectados en la red eléctrica residencial. Para este experimento, primero se instaló el sistema propuesto en 20 hogares de Santiago de Chile. Cada hogar cuenta con equipo de medición y comunicación ILM, instalado en cada toma de corriente del hogar. Los perfiles eléctricos de los artefactos domésticos se construyeron y estudiaron en base a datos que provienen de múltiples marcas y modelos presentes en los hogares de colaboradores en esta investigación.

Para obtener los datos de consumo eléctrico, se midió el funcionamiento a través de un sistema de carga intrusivo por medio de un AMR de baja resolución, el cual registró el comportamiento del electrodoméstico en términos de potencia activa consumida en múltiples condiciones de funcionamientos (bajo, medio y alto performance). Se obtuvieron entre 50 y 80 muestras de cada una de las variables para cada artefacto medido: hervidor, refrigerador, horno eléctrico, microondas, calefactor, lavadora, parrilla eléctrica, router, entre otros. El sistema de carga intrusivo registró una muestra de medición del consumo eléctrico en potencia activa, cada 20 segundos y se midió el comportamiento durante 5 minutos de funcionamiento, es decir: 20 (s), 40 (s), 80 (s), hasta 300 (s). Sin embargo, solo se usaron los primeros 220 (s) en el dataset del modelo de entrenamiento de la ANN, construyendo de esta manera, una matriz de datos de 11 columnas, donde cada una representa una entrada para el modelo de ANN. Es importante destacar que se realizaron mediciones en 20 hogares, durante 90 días entre el 29 de marzo al 30 de junio, estación otoñal. Sin embargo, con un registro de 300 (s) es suficiente para entrenar y reconocer los perfiles de los artefactos. Estos datos fueron preprocesados

matricialmente, pero no requirieron filtrado debido a la escasa presencia de ruido aditivo.

Las mediciones se realizan en 22 artefactos, de los cuales 9 son mostrados en los resultados finales de este artículo, y 6 de éstos, los más típicos empleados en los hogares, utilizados para realizar el entrenamiento de la ANN. La Fig. 4 muestra el comportamiento característico de cada uno de los 6 artefactos en función de la potencia activa demandada durante 3 minutos de operación.




Fig. 4. Perfil de consumo de cada artefacto.

Aunque el comportamiento energético de manera global tiende a ser complejo de visualizar, si se separan las curvas de forma intuitiva, se puede apreciar que algunos artefactos tienen comportamientos similares en relación con la potencia demandada, como es el caso del hervidor, el calefactor y el horno eléctrico (Fig. 5).




Fig. 5. Potencia activa demandada en hervidor, calefactor y horno eléctrico

Estos tres electrodomésticos incorporan elementos de tipo resistivo en sus componentes eléctricos, los que en el fondo describen su principal función de generar calor mediante energía eléctrica. Sin embargo, el hervidor una vez alcanzada una temperatura máxima, deja de funcionar, a diferencia de los otros artefactos que funcionan bajo rangos de temperatura, activando y desactivando su funcionamiento durante un periodo de tiempo.

Por otro lado, la curva de consumo de un refrigerador, como se muestra en Fig. 6, es muy característica y no es similar a ninguna otra curva estudiada.

Estos elementos que son capaces de ser visualizados y diferenciados de manera intuitiva son los que se busca medir y parametrizar a través del uso de técnicas de Machine Learning (ML), para detectar y predecir el artefacto eléctrico medido según su comportamiento eléctrico en función del tiempo de uso.

En Fig. 7, se muestran los comportamientos registrados para los equipos de microondas y lavadora durante los intervalos de

tiempo. Para ambos se observa un ciclo de trabajo similar y que genera algunas complicaciones en su identificación.




Fig. 6. Perfil de potencia activa en un refrigerador.




Fig. 7. Patrón de consumo de potencia activa de microondas y lavadora.

B. Machine Learning Process

Una vez obtenidos los datos del consumo eléctrico de los artefactos domésticos estudiados, se procede a generar una matriz de datos e información que fue utilizada para entrenar el modelo.

Esta etapa está sistematizada como lo muestra la Fig. 8. El primer paso es preparar los datos a utilizar. Para esto se eliminan los datos erróneos, se estudian y se escogen las características que serán utilizadas y además se desestiman los factores que no son influyentes en los resultados predictivos.

Esta matriz, se divide en sub-matrices para ser utilizadas en las etapas de entrenamiento de la red neuronal, en el testeo y posterior validación del modelo.

La segunda etapa consta de preparar y parametrizar el modelo. En el caso de la red neuronal utilizada, se generó en Matlab® con un script de ANN mejorado, el cual busca y encuentra la mejor red neuronal en base a los resultados de predicción obtenidos, variando los parámetros de la red tales como: número de capas ocultas, neuronas de la capa oculta, tasa de aprendizaje, y porcentaje de datos en las submatrices de entrenamiento, testeo y validación [11],[12]. Esto permite que los resultados obtenidos de la simulación sean los mejores y por ende definir la estructura del modelo.

Evaluar el modelo generado es parte de la etapa tres, en que el método utilizado para entrenar la red neuronal debe ser probado con un nuevo conjunto de datos. Esta evaluación debe realizarse a partir de mediciones de nuevos artefactos, no utilizados en el entrenamiento anterior, de tal manera que se puedan someter a comparación, realizando así una evaluación más amplia y, además, conocer cuán preciso puede llegar a resultar el modelo propuesto.

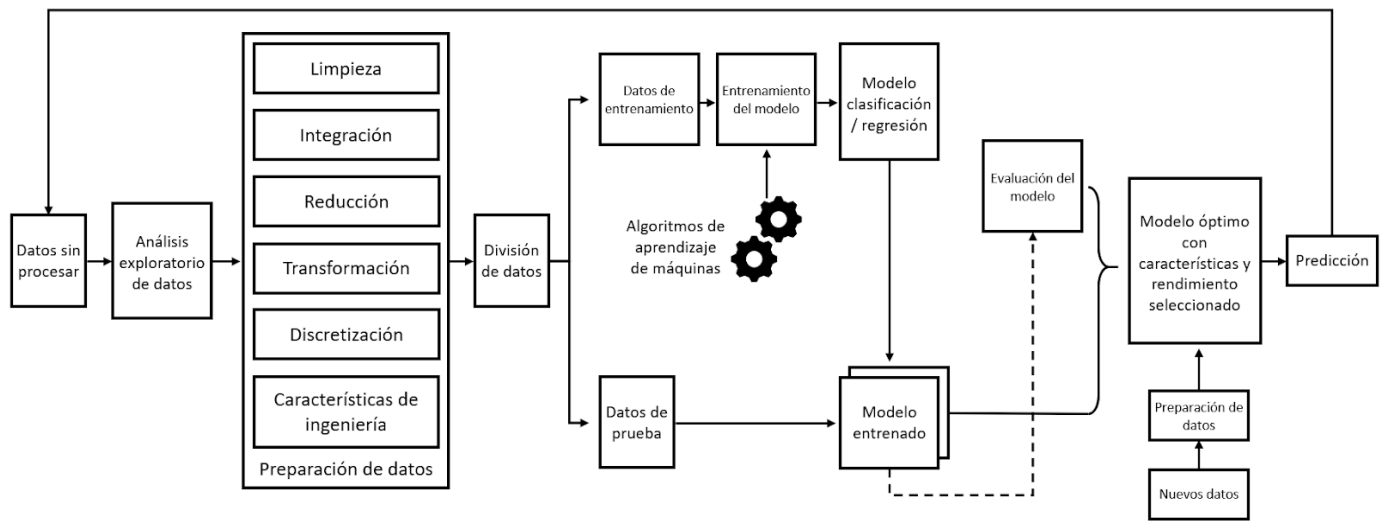


Fig. 8. Metodología de procesamiento de datos para entrenamiento y testeo de ANN [4].

C. Resultados Obtenidos

Utilizando los SS se obtienen los registros de 22 artefactos diferentes, medidos con una resolución de 20 segundos. De los 9 artefactos del hogar (Fig 6, Fig. 9 a Fig. 16), se presentan sus respectivos patrones de consumo de potencia activa:




Fig. 9. Patrón de consumo de potencia activa de una cafetera. Tiempo de medición en intervalos de 3 horas.




Fig. 10. Patrón de consumo de potencia activa de un calefactor. Tiempo de medición en intervalos de 48 horas.




Fig. 11. Patrón de consumo de potencia activa de una parrilla eléctrica. Tiempo de medición en intervalos de 12 horas.

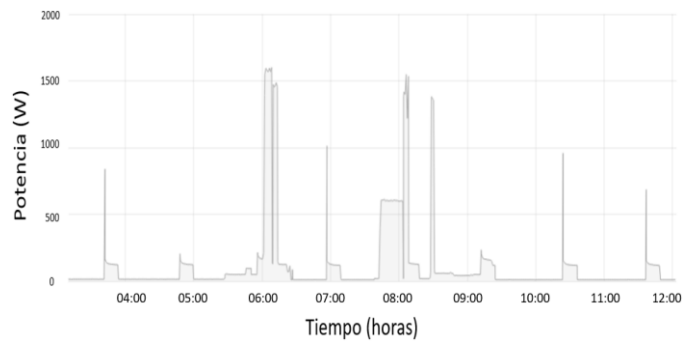


Fig. 12. Patrón de consumo de potencia activa de un microondas. Tiempo de medición en intervalos de 9 horas.

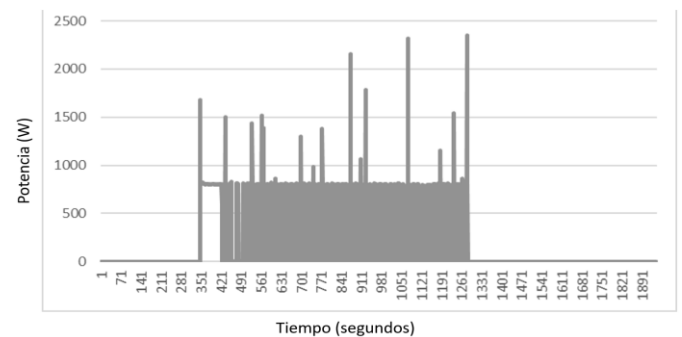


Fig. 13. Patrón de consumo de potencia activa de un homo eléctrico. Tiempo de medición en intervalos de 30 min.




Fig. 14. Patrón de consumo de potencia activa de una lavadora. Tiempo de medición en intervalos de 60 min.




Fig. 15. Patrón de consumo de potencia activa de una aspiradora. Tiempo de medición en intervalos de 5 horas.

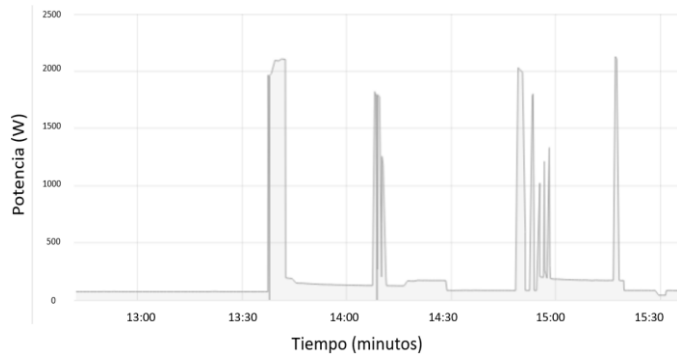


Fig. 16. Patrón de consumo de potencia activa de un router. Tiempo de medición en un intervalo de 4 horas.

V. DISCUSIÓN DE LOS RESULTADOS

Se procedió a ejecutar modelos basados en técnicas de Machine Learning con el Software RapidMiner y Matlab®. Solo un modelo de un total de 10 logra un resultado sobre el 90% de predicción, este fue ANN, tal como se muestra en Fig. 17. Mediante el uso de Matlab®, se ejecutó el algoritmo de ANN, programado para encontrar la mejor versión y configuración de los hiperparámetros del modelo. El algoritmo de ANN se aplica para 6 diferentes electrodomésticos con un 91.7% de eficacia en términos globales, como muestra la Tabla I.

El hervidor, calefactor y horno eléctrico tienen componentes resistivos y tienden a confundirse. El modelo realiza predicciones erradas, tal como se intuía desde un principio revisando los resultados desde Fig. 4 a Fig. 7. El funcionamiento de estos tres artefactos, en ocasiones suelen ser muy similares y el algoritmo no es capaz de separar eficazmente los datos según sus características de consumo energético.

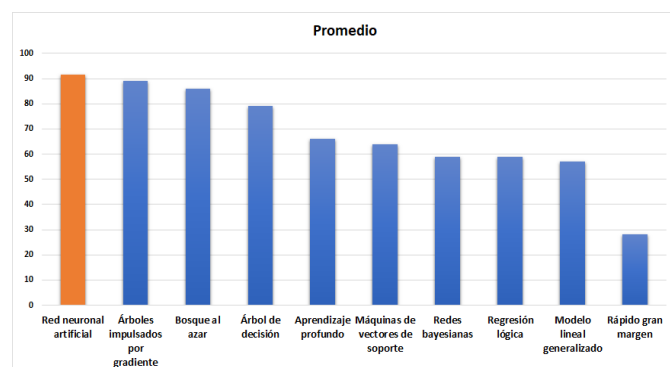


Fig. 17. Exactitud para distintos modelos de Machine Learning.

En Tabla I, cada columna entrega los resultados de reconocimiento con respecto a cada artefacto definido en cada fila. Por ejemplo, la columna del artefacto hervidor indica que el modelo propuesto reconoce a su propio artefacto con un 86.6% de exactitud, lo asimila con un horno eléctrico y con un calefactor en un 6.7%.

TABLA I
MATRIZ DE PREDICCIÓN DE DISPOSITIVOS

	Hervidor	Refrigerador	Horno eléctrico	Micro-ondas	Calefactor	Lavadora
Hervidor	86.6%	1.6%	0%	4.2%	8.5%	0%
Refrigerador	0%	98.4%	1.9%	1.4%	0%	0%
Horno eléctrico	6.7%	0%	94.4%	5.6%	0%	0%
Micro-ondas	0%	0%	0%	83.3%	0%	3.3%
Calefactor	6.7%	0%	3.7%	1.4%	91.5%	0%
Lavadora	0%	0%	0%	4.1%	0%	96.7%
Precisión	86.6%	98.4%	94.4%	83.3%	91.5%	96.7%
Error	13.4%	1.6%	5.6%	16.7%	8.5%	3.3%

El procedimiento para el resto de las columnas es similar al mostrado. Cada columna suma el total de 100% de los resultados obtenidos. Las sumas de las filas no tienen significado alguno.

El refrigerador en cambio es el artefacto con mayores probabilidades de ser detectado eficazmente con un 98.4%. Por otro lado, el microondas y la lavadora son artefactos que el algoritmo tiende a confundir ya que mantienen ciclos de funcionamiento algo similares.

Para aumentar el rendimiento del algoritmo, se propone aislar el problema en subcategorías, se agrupa el conjunto de datos mediante el uso de técnicas de clustering, se pudo validar esta hipótesis, ya que se aislaron los datos de las mediciones de hervidor, calefactor y horno eléctrico para generar un nuevo dataset sólo con estos targets.

El resultado de esta prueba se muestra en Tabla II, en donde se logra apreciar que la precisión de este algoritmo con la técnica previa de clúster mejora los resultados para el hervidor pasando de un 86.6% a un 95.1%, en el calefactor se aumenta del 91.5% a un 95.7% y en el horno eléctrico cambia de 94.4% a 98.1%. Estos resultados son mejores que los reportados por Ridi *et al.* en [6].

Lo mismo ocurre en el caso del clúster 2, que agrupa a microondas y lavadora, donde mejora sustancialmente el rendimiento del algoritmo cuando se aíslan los artefactos según similitudes pasando de un 83.3% y 96.7% a un 100% de identificación respectivamente. Los resultados son mostrados en Tabla III

TABLA II
MATRIZ COMPARATIVA DE PREDICCIÓN ENTRE HERVIDOR, HORNO ELÉCTRICO Y CALEFACTOR. CLÚSTER 1.

	Hervidor	Horno eléctrico	Calefactor
Hervidor	95.1%	1.9%	4.3%
Horno eléctrico	0%	98.1%	0%
Calefactor	4.9%	0%	95.7%
Precisión	95.1%	98.1%	95.7%
Error	4.9%	1.9%	4.3%

TABLA III
MICROONDAS Y LAVADORA. CLÚSTER 2.

	Micro-ondas	Lavadora
Micro-ondas	100%	0%
Lavadora	0%	100%
Precisión	100%	100%
Error	0%	0%

VI. CONCLUSIONES

La investigación propuesta permite reconocer los perfiles característicos de un conjunto de electrodomésticos con precisiones que van desde un mínimo de 83.3% para el microondas hasta un máximo de un 98.4% para el refrigerador. La incorporación de una etapa de clúster a la metodología propuesta permite aumentar el nivel de precisión siendo el mínimo de 95.1% para el hervidor y de 100% para microonda y lavadora.

De los resultados obtenidos se concluye que es posible predecir perfiles de consumos en electrodomésticos, con altos niveles de certidumbre, alta velocidad de muestreo y bajo múltiples estados de funcionamiento.

Entre las limitaciones de la investigación se puede mencionar la necesidad de validar la propuesta a gran escala y el uso de una red neuronal básica que demandó más de un clustering para la diferenciación temprana.

Estos resultados alientan el desarrollo de soluciones que a través del reconocimiento automático de los dispositivos eléctricos permitirán avanzar en la autogestión y en el fomento de la participación de los ciudadanos en la eficiencia energética.


Como trabajo futuro, se espera poder comparar el desempeño de esta red neuronal con otras técnicas de inteligencia artificial de optimización, y desarrollar una herramienta informática que permita el monitoreo y control remoto de artefactos en el hogar.

REFERENCIAS

- [1] H. Shareef, M. S. Ahmed, A. Mohamed, and E. A. Hassan, "Review on home energy management system considering demand responses, smart technologies, and intelligent controllers," *IEEE Access*, vol. 6, pp. 24498–24509, 2018. DOI: 10.1109/ACCESS.2018.2831917.
- [2] Y.H. Lin, and M.-S. Tsai, "An advanced home energy management system facilitated by nonintrusive load monitoring with automated multiobjective power scheduling," *IEEE Trans. Smart Grid*, vol. 6, no. 4, pp. 1839–1851, 2015. DOI: 10.1109/TSG.2015.2388492.
- [3] T. Hasan, F. Javed, and N. Arshad, "An empirical investigation of V-I trajectory-based load signatures for non-intrusive load monitoring," *IEEE Trans. Smart Grid*, vol. 5, no. 2, pp. 870–878, 2013. DOI: 10.1109/TSG.2013.2271282.
- [4] F. P. Guo-ying, Y. Yu-yao, H. Guangyu, "The pattern recognition of residential power consumption based on HMM", 2018 IEEE Conference Paper Innovate Smart Grid Technologies – Asia (ISGT Asia).
- [5] T. Kato, H. S. Cho, D. Lee, T. Toyomura, and T. Yamazaki, "Appliance recognition from electric current signals for information-energy integrated network in home environments," *Ambient Assistive Health and Wellness Management in the Heart of the City*, vol. 5597, pp. 150–157, 2009.
- [6] A. Ridi, C. Gisler, and J. Hennebert, "Automatic identification of electrical appliances using smart plugs," 2013 *8th Inter. Workshop on Systems, Signal Processing and their Applications (WoSSPA)*, Algiers, Algeria, 2013. DOI: 10.1109/WoSSPA.2013.6602380.
- [7] A. Ridi, C. Gisler, and J. Hennebert, "A survey on intrusive load monitoring for appliance recognition," 2014 *22nd Inter. Conf. on Pattern Recognition*, Stockholm, Sweden, 2014. DOI: 10.1109/ICPR.2014.636.
- [8] F. Ulloa-Vásquez, L. García-Santander, D. Carrizo, and C. Hurtado, "Towards a home energy management model through a coordinator of smart sockets," *Latvian Journal of Physics and Technical Sciences*, vol. 4, no. 55, pp. 35–43, 2018.
- [9] P. Pawar, and K. P. Vittal, "Design of smart socket for power optimization in home management system", 2017 *2nd IEEE Inter. Conf. on Recent Trends in Electronics, Information & Communications Technology (RTEICT)*, pp.1739–1744, 2017. DOI: 10.1109/RTEICT.2017.8256897.
- [10] Carlos Cruz; Esther Palomar; Ignacio Bravo; Alfredo Gardel. "Towards Sustainable Energy-Efficient Communities Based on a Scheduling Algorithm". *Sensor MDPI*. Published: 14 September 2019. Sensors 2019, 19, 3973; DOI:10.3390/s19183973.
- [11] Manzoor, Awais & Ahmed, Fahim & Judge, Malik & Ahmed, Adnan & Mirza, Aamad & Khan, Zahoor & Qasim, Umar & Javaid, Nadeem. (2018). "User Comfort Oriented Residential Power Scheduling in Smart Homes". *Advances in Intelligent Systems and Computing*, July 2018. DOI: 10.1007/978-3-319-61542-4. In book: Innovative Mobile and Internet Services in Ubiquitous Computing, pp.171–180.
- [12] Nagender Kumar Suryadevara; Gyan Ranjan Biswa. "Smart Plugs: Paradigms and Applications in the Smart City-and-Smart Grid". *Energy MDPI*. Energies 2019, 12(10), 1957;.
- [13] A. Obushevs, I. Oleinikova and A. Mutule, "Demand side management platform for HAN flexibility estimation with agent control", 2016 *13th Inter. Conf. on the Eur. Energy Market (EEM)*, Porto, Portugal, 2016. DOI: 10.1109/EEM.2016.7521185.
- [14] M. N. Ullah1, N. Javaid1,2, I. Khan1, A. Mahmood2, M. U. Farooq, "Residential Energy Consumption Controlling Techniques to Enable Autonomous Demand Side Management in Future Smart Grid Communications", 2013 *Eighth International Conference on Broadband, Wireless Computing, Communication and Applications*, pp.545–550, *IEEE Computer Society*. DOI 10.1109/BWCCA.2013.94.
- [15] F. Paradiso, F. Paganelli, A. Luchetta, D. Giuli, and P. Castrogiovanni, "ANN-based appliance recognition from low-frequency energy monitoring data," 2013 *IEEE 14th Inter. Symp. on "A World of Wireless, Mobile and Multimedia Networks"* (WoWMoM), Madrid, Spain, 2013. DOI: 10.1109/WoWMoM.2013.6583496.
- [16] Yi-Cheng Chen; Yu-Lun Ko; Wen-Chih Peng; "An Intelligent System for Mining Usage Patterns from Appliance Data in Smart Home Environment"; 2012 *Conference on Technologies and Applications of Artificial Intelligence 2012; Conference Paper : IEEE*
- [17] Sylvain Guillemin; Duy Long Ha; "Fuzzy and parametric method for self-configuration of home energy manager system", 2013 *IEEE Grenoble Conference; 2013; Conference Paper | Publisher: IEEE*.
- [18] Yun Gao; Honggeng Yang; "Non-Intrusive Load Identification by Fuzzy Cluster Analysis Based on Active Power", 2012 *Asia-Pacific Power and Energy Engineering Conference; 2012 | Conference Paper | Publisher: IEEE*.
- [19] Antonio Ridi; Christophe Gisler; Jean Hennebert; "ACS-F2 — A new database of appliance consumption signatures", 2014 *6th International Conference of Soft Computing and Pattern Recognition (SoCPaR) Year: 2014 | Conference Paper | Publisher: IEEE*
- [20] Lei Jiang; Suhuai Luo; Jiaming Li; "Intelligent electrical event recognition on general household power appliances", 2014 *IEEE 15th Workshop on Control and Modeling for Power Electronics (COMPEL) Year: 2014 | Conference Paper | Publisher: IEEE*.
- [21] Wesllen S. Lima; Eduardo Souto; Thiago Rocha; Richard W. Pazzi; Ferry Pramudianto; "User activity recognition for energy saving in smart home environment", 2015 *IEEE Symposium on Computers and Communication (ISCC) Year: 2015 | Conference Paper | Publisher: IEEE*.
- [22] Qie Sun; Hailong Li; Zhanyu Ma; Chao Wang; Javier Campillo; Qi Zhang; Fredrik Wallin; Jun Guo, "A Comprehensive Review of Smart Energy Meters in Intelligent Energy Networks", *IEEE Internet of Things Journal* Year: 2016 | Volume: 3, Issue: 4 | Journal Article | Publisher: IEEE.
- [23] Marcel Lowell G. Villanueva; Samuel Matthew G. Dumlaog; Rosula S. J. Reyes, "Appliance recognition system for ILM using AGILASx — Dataset of common appliances in the Philippines", 2016 *Cloudification of the Internet of Things (CIoT) Year: 2016 | Conference Paper | Publisher: IEEE*.
- [24] Maher Azaza; Fredrik Wallin, "Supervised household's loads pattern recognition", 2016 *IEEE Electrical Power and Energy Conference (EPEC) Year: 2016 | Conference Paper | Publisher: IEEE*
- [25] Vanh Khuyen Nguyen; Minh-Hieu Phan; Wei Emma Zhang; Quan Z. Sheng; Trung Duc Vo, "A Hybrid Approach for Intrusive Appliance Load Monitoring in Smart Home", 2020 *IEEE International Conference on Smart Internet of Things (SmartIoT); 2020 | Conference Paper; IEEE*.
- [26] Prajna Dash; Kshirasagar Naik, "A Very Deep One Dimensional Convolutional Neural Network (VDOCNN) for Appliance Power Signature Classification", 2018 *IEEE Electrical Power and Energy Conference (EPEC) Year: 2018 | Conference Paper | Publisher: IEEE*
- [27] MPAWENIMANA; Alain PEGATOQUET; Win Thandar SOE; Cécile BELLEUDY, "Appliances Identification for Different Electrical Signatures using Moving Average as Data Preparation Innocent", 2018

- Ninth International Green and Sustainable Computing Conference (IGSC) Year: 2018 | Conference Paper | Publisher: IEEE.
- [28] Emir Salihagić; Jasmin Kevric; Nejdet Dođru, "Classification of ON-OFF states of appliance consumption signatures", 2016 XI International Symposium on Telecommunications (BIHTEL) Year: 2016 | Conference Paper | Publisher: IEEE.
- [29] Christoph Klemenjak; Wilfried Elmenreich, "On the applicability of correlation filters for appliance detection in smart meter readings", 2017 IEEE International Conference on Smart Grid Communications (SmartGridComm) Year: 2017 | Conference Paper | Publisher: IEEE.
- [30] Abhinav Gupta; Priyans Murarka, "A Ubiquitous Sensor Network for Domestic Energy Monitoring and Energy Consumption Optimization", 2012 IEEE International Conference on Green Computing and Communications Year: 2012 | Conference Paper | Publisher: IEEE.

investigación/interés son ciencias de la computación, gestión de TI, radiocomunicación, IoT y vehículos autónomos.



Fernando Ulloa Vásquez recibió su título de Ingeniero Electrónico de la Universidad Tecnológica Metropolitana (UTEM), Chile, en 1992, y de PhD. Ingeniería en Telecomunicaciones por la Universidad Politécnica de Cataluña en 2003. Es Profesor Titular en el Departamento de Electricidad de la UTEM. Sus áreas de

Investigación son las aplicaciones de Sistemas de radio aeronáuticos y de canal para plataformas estratosféricas HAAP de banda ancha digital Terrestre.




Luis García Santander recibió su título de Ingeniero Civil Eléctrico de la Universidad de Concepción, Chile, en 1995 y en 2003 su grado de Doctor en Ingeniería Eléctrica de la l'École Supérieure d'Électricité (Supélec) – Université Pierre et Marie Curie Paris VI, Paris-Francia. Es Profesor Asociado en el

Departamento de Ingeniería Eléctrica en la Universidad de Concepción, Chile. Sus áreas de interés son la optimización de Sistemas Eléctricos, Gestión Eficiente de la Energía, Redes Inteligentes y Energías Renovables.



Dante Carrizo Moreno recibió su título de Ingeniero Civil Informático de la Universidad de Concepción, Chile. Es M.Sc. y Ph.D. en Ingeniería en Software de la Universidad Politécnica de Madrid, España. Es Profesor Titular y decano de la Facultad de Ingeniería de la Universidad de Atacama, Chile. Sus áreas de interés son

Ingeniería de Software, Big Data y Minería de Datos. Ha sido revisor de artículos para diversas revistas científicas y conferencias internacionales de su disciplina.



Víctor Heredia Figueroa recibió su grado académico de Licenciado en Ciencias de la Ingeniería el año 2018 en la Universidad Tecnológica Metropolitana (UTEM) y es Ingeniero Civil en Computación (e) de la misma casa de estudios. Víctor desde el año 2017 a la fecha se desempeña como investigador junior en el Programa de

Investigación en Radiocomunicación Digital y sus áreas de