

SISTEMA DOMÓTICO PARA LA GESTIÓN DE DEMANDA DE UNA VIVIENDA AUTOSOSTENIBLE

DOMOTIC SYSTEM FOR THE DEMAND MANAGEMENT OF A SELF-SUSTAINABLE HOUSING

Kevin Andrés Suaza Cano¹
kevin.suaza00@usc.edu.co

Angel Stiven Angulo Gamboa¹
angel.angulo00@usc.edu.co

Javier Ferney Castillo García²
javier.castillo00@usc.edu.co

Universidad Santiago de Cali, Facultad de Ingeniería, Programa de Ingeniería Electrónica

Resumen

Se desarrolló un sistema de caracterización de cargas en una plataforma embebida, con la finalidad de identificar dispositivos eléctricos usados en el hogar. Para el proceso de caracterización se definieron los parámetros eléctricos más representativos de las distintas cargas, los cuales fueron utilizados en el entrenamiento de una red neuronal artificial implementada en una plataforma embebida con una topología de red con el mejor desempeño en términos de recurso computacional, tiempo de ejecución y porcentaje de error. La estructura de la red utilizó dos capas ocultas cada una con 10 neuronas, obteniendo un error promedio de 2.051% con una desviación estándar de 1.23%. Con la caracterización de cargas eléctricas se logró plantear un sistema domótico inteligente el cual puede generar un ahorro de hasta el 23% con respecto a los sistemas domóticos tradicionales o un 69% de ahorro en comparación a una vivienda sin ningún tipo de automatización o sistema de control. El sistema de gestión de demanda propuesto puede gestionar de forma activa las cargas debido al conocimiento de los elementos conectados a la red, identificando los períodos de bajo consumo lo cual puede relacionarse a procesos de carga finalizada en celulares, computadores portátiles o modo de espera en televisores. La identificación de cargas facilita la implementación de esquemas de gestión y control de cargas eléctricas.

Palabras Clave: Domótica; Caracterización de Cargas Eléctricas; Redes Neuronales Artificiales; Máquinas de Aprendizaje; Sistema Embebido.

Abstract

A load characterization system was developed in an embedded platform, in order to identify electrical devices used in the home. For the characterization process, the most representative electrical parameters of the different loads were defined, which were used in the training of an artificial neural network implemented in an embedded platform with a network topology with the best performance in terms of computational resources, time of execution and percentage of error. The structure of the network used two hidden layers each with 10 neurons, obtaining an average error of 2.051% with a standard deviation of 1.23%. With the characterization of electrical charges, an intelligent home automation system could be created which can generate savings of up to 23% compared to traditional home automation systems or 69% savings compared to a home without any automation or system control. The proposed demand management system can actively manage the loads due to the knowledge of the elements connected to the network, identifying periods of low consumption which can be related to charging processes completed in mobile phones, laptops or standby mode for televisions. The identification of charges facilitates the implementation of management schemes and control of electric charges.

Keywords: Home automation; Characterization of Electric Charges; Artificial Neural Network; Learning Machines; Embedded System.

1. INTRODUCCIÓN

Actualmente el consumo energético en los hogares es elevado, esto es consecuencia de una eficiencia energética muy baja, lo cual se traduce en un alto impacto al medio ambiente, esto hace necesario tener mayor grado de control sobre los

dispositivos eléctricos que se utilizan en el hogar, haciendo así de la domótica una herramienta muy útil en la automatización de la conexión y desconexión de electrodomésticos en el hogar, aspectos relacionados al confort, la seguridad y la eficiencia en el uso razonable de los recursos eléctricos. En principio la domótica se restringía a ser una herramienta a la mano del usuario, brindando la capacidad de poder hacer algunos ajustes sobre la vivienda como encender o apagar luces, o configurar temporizadores, sin embargo, la tecnología ha avanzado muy rápido y a la domótica se le han asignado tareas más complejas con el pasar de los años. Vivir en un hogar inteligente es pertenecer a un espacio que se adapta fácilmente a nuestras necesidades y, en la mayoría de los casos, de un modo automático.

Si se analiza el mercado actual se pueden encontrar distintos avances en lo que a seguridad, energía y confort se refiere

1.1 Seguridad

La seguridad y vigilancia es una de las áreas donde más crecimiento ha tenido la domótica, se han desarrollado grandes avances en área de vigilancia, en donde las cámaras inteligentes son tendencia a nivel mundial, estas brindan la posibilidad de poder acceder a sus imágenes mediante una conexión a internet desde cualquier parte del mundo y no solo esto, también brindan la capacidad de ejercer control sobre ellas, como cambiar la posición hacia la que apuntan, iniciar o detener la grabación y en los modelos más avanzados poder ejecutar algoritmos de reconocimiento facial. Otro de los grandes aspectos en los que ha evolucionado la domótica en términos de seguridad, es poder realizar control sobre las puertas, ventanas y persianas de la vivienda, logrando así, la capacidad de abrir o cerrar puertas y ventanas e inclusive informar sobre violaciones de seguridad en la vivienda o dar acceso mediante tecnología biométrica (Siswanto, Katuk, & Ku-Mahamud, 2016) (Taryudi, Bagas Adriano, & Ciptoning Budi, 2018).

1.2 Energía

Uno de los más importantes rasgos de la domótica y una de sus principales características, es que en general cuenta con la capacidad de realizar control sobre distintos aparatos del hogar que influyen directamente sobre el consumo energético, en áreas como la climatización y la iluminación. Los nuevos avances traen consigo tecnologías como termostatos inteligentes, los cuales tienen la capacidad de realizar un control preciso sobre los dispositivos de aire acondicionado o calefacción, o los más comunes, como son los sistemas de iluminación inteligentes, quienes brindan con la capacidad de variar su intensidad lumínica basados en la actividad del usuario o teniendo información sobre la presencia de personas en el hogar, todo esto con el fin de generar un ahorro energético y tener un mejor aprovechamiento de los recursos (Guerard, Levy, & Pousseur, 2018) (Escobar Gallardo & Villazón, 2018).

1.3 Confort

Una de las grandes tendencias en lo que a domótica y automatización en el hogar se refiere, es el uso de asistentes personales como Google Home, o Amazon Alexa, este tipo de dispositivos cuentan con la capacidad de reconocer comandos de voz del usuario y recibir órdenes directas de este, aunque una de sus principales características es la capacidad que tienen para relacionarse con distintos dispositivos para el hogar, logrando que la comunicación entre el usuario y los dispositivos de control se realice de la forma más natural posible, este tipo de dispositivos también implementan técnicas de inteligencia artificial y al tener acceso a los datos del teléfono inteligente del usuario logran generar rutinas diarias basadas en el comportamiento de las personas del hogar (Ciabattoni, Ferracuti, Ippoliti, Longhi, & Turri, 2016) (Ammari, Kaye, Y. Tsai, & Bentley, 2019).

El objetivo de este artículo es presentar la implementación de una red neuronal artificial en un sistema embebido para la caracterización de cargas eléctricas para la gestión de demanda eléctrica en un sistema domótico, donde una de sus principales características es la versatilidad en la implementación de diferentes topologías de red y la definición de los parámetros eléctricos que posibiliten modelar o caracterizar las cargas eléctricas más comunes en un hogar.

2. ANTECEDENTES

Se presentan estudios relacionados a los sistemas domóticos basados en la gestión de demanda o sistemas de control

de conexión y desconexión de cargas. Los sistemas ampliamente utilizados comparten características similares tales como, definición del hardware para los protocolos de comunicación, sistema de control de cargas (contactores o estado sólido), uso de temporización o definición manual para el tiempo de conexión y desconexión de los distintos dispositivos eléctricos.

En primera instancia (Hassanpour, Rajabi, Shayan, Hafezi, & Arefi, 2017) aborda la problemática del consumo excesivo de los recursos eléctricos en el hogar y plantea la necesidad que se tiene de implementar sistemas de automatización de forma masiva.

El aspecto más básico de la domótica, es la capacidad de realizar control sobre alguno o varios aspectos de la vivienda, como realizar encendido y apagado de luces o dispositivos conectados a la red eléctrica (Ovalles, Bolivar, & Rodriguez, 2018) y poder brindar información sobre aspectos básicos como temperatura, humedad (Dobrescu, 2014) y en algunos casos información más detallada como intensidad lumínica, detección de movimiento y campos magnéticos para detectar apertura de puertas o ventanas (Banu, Merlin, & Suhitha, 2018). En el trabajo de investigación de (Morón, Payán, García, & Bosquet, 2016), se realiza la implementación de un sistema de domótica tradicional utilizando tecnología KNX en una vivienda de 67m², este sistema aunque confiable se convierte en obsoleto a comparación de propuestas tecnológicas como la realizada por (García & Vega, 2018), en su trabajo de investigación se realiza la implementación de un sistema de encendido y apagado descentralizado, utilizando módulos ESP8266 conectados mediante una red inalámbrica, lo que le permite mayor nivel de flexibilidad y facilidad de implementación, todo esto en conjunto con un menor costo total del sistema.

Una de las áreas donde la domótica tiene mayor capacidad de evolución, es en la toma de decisiones de forma automática, brindar a la domótica la capacidad de decidir qué dispositivos eléctricos están o no conectados a la red eléctrica, permite realizar un control más preciso sobre el consumo eléctrico de la vivienda. En la literatura se han realizado diferentes aproximamientos a esta idea y se han encontrado propuestas que tienen la capacidad de generar un ahorro eléctrico, (Moya CH., 2018) en su trabajo de investigación realiza un sistema de agendamiento de cargas eléctricas, con el cual logra realizar el adecuado uso del recurso fotovoltaico con el que cuenta una vivienda, haciendo uso en menor medida de la red eléctrica domiciliaria, sin embargo, se han encontrado variedad de trabajos en los cuales el objetivo es realizar un sistema que pueda realizar la clasificación de cargas eléctricas en base a sus señales de voltaje y corriente, (Toro Betancur, 2017) realiza una aproximación a esta idea, haciendo uso de Redes Neuronales Artificiales logra la identificación de características fundamentales en una señal de radio, por su parte, (Bouazzaoui Cherraqi & Maach, 2018) desarrollan un sistema con la capacidad de identificar correctamente un refrigerador utilizando una ANN entrenada únicamente con los datos de potencia del dispositivo, (García Ortiz, 2016) realiza un sistema similar, sin embargo en su desarrollo se utilizan los datos de consumo general de la vivienda y con el uso de la transformada Hilbert-Huang logra una correcta caracterización de elementos con gran consumo energético como la lavadora, secadora de ropa y refrigerador.

El sistema domótico propuesto, realizará una caracterización e identificación de cargas eléctricas, el cual cuenta con la capacidad de identificar un electrodoméstico y su modo de funcionamiento (carga plena o bajo consumo). La caracterización utiliza parámetros eléctricos que modelan las diferentes cargas desde sus características en potencia, distorsión armónica entre otras. La gestión de demanda utiliza la información de los electrodomésticos conectados a la red y establece su modo de funcionamiento, aquellos en bajo consumo son desconectados posterior a su identificación. El ecosistema se conforma por módulos de tomacorrientes, módulos de interruptores y un módulo maestro donde se definen las acciones que dependen del electrodoméstico identificado. La activación de las cargas se realizará con dispositivos electrónicos de potencia de estado sólido.

Algunos de los sistemas presentados realizan el proceso de activación usando relevadores electromecánicos lo cual trae consigo desgaste de los contactos y mayores acciones de mantenimiento.

3. MATERIALES Y MÉTODOS/METODOLOGÍA

3.1 Sistema embebido

Se diseñó y elaboró un sistema embebido, el cual permitió la adquisición de datos de voltaje y corriente, de cada uno de los electrodomésticos más comunes en los hogares, y luego se utilizaron estos datos para extraer los parámetros eléctricos que permitieron diferenciar los distintos electrodomésticos y sus estados de consumo. Se presentan los elementos *hardware* y *software* utilizados en el proceso de desarrollo del sistema embebido:

3.1.1 Hardware

Una de las características fundamentales en la selección de la plataforma fue la capacidad de cumplir las necesidades de la fase de desarrollo y que pudiera utilizarse como un producto final. Se plantearon los requerimientos necesarios, un sistema embebido que pueda tener lectura sobre voltaje y corriente alterna (AC), que cuente con diferentes medios de comunicación inalámbrica, para su posterior implementación en un sistema domótico, que cuente con grandes capacidades de memoria y un alto poder de cómputo para la implementación del sistema de caracterización. La Tabla 1 presenta las diferentes plataformas de desarrollo consideradas para el sistema embebido y sus principales características, teniendo como principal objetivo una plataforma de bajo costo, facilidad en la implementación de una red de comunicación inalámbrica con un alto nivel de procesamiento y capacidad suficiente de memoria. La plataforma de desarrollo seleccionada fue la ESP32, dado que su precio, cuenta con un potente procesador de doble núcleo Xtensa LX6 de 32 Bits a 240MHz, memoria flash de 4MB para el programa y 540KB de memoria RAM integrada, comunicación WI-FI b/g/n y Bluetooth 4.2 Low Energy integrados y la posibilidad de realizar lectura de voltaje análogo con una resolución de 12 Bits. Las demás plataformas que cuentan con características similares tienen la desventaja de ser más costosas imposibilitando el desarrollo de un sistema de bajo costo.

Tabla 1: Tabla comparativa de las diferentes plataformas de desarrollo disponibles en el mercado. Fuente: Autores.


Plataforma	Microcontrolador	Interfases	Memoria Flash (B)	SRAM (B)	Velocidad (MHz)	WI-FI	BT	Costo (US \$)
Arduino UNO	ATmega328 (8BIT)	1UART, 6PWM(8BIT), 1SPI, 1I2C, 6ADC(10BIT)	32K	2K	16	NO	NO	\$10
Arduino DUE	ARM SAM3X8E (32BIT)	4UART, 11PWM(12BIT), 1SPI, 1CAN, 2I2C, 2DAC(12BIT)	512K	96K	84	NO	NO	\$20
ESP8266	Tensilica Xtensa LX106 (32BIT)	1UART, 16PWM(10BIT), 2SPI, 1I2C, 1I2S, 1ADC(10BIT)	1M	64K	160	IEEE 802.11 b/g/n	NO	\$12
ESP32	2X Xtensa LX6 (32BIT)	3UART, 16PWM(16bit), 4SPI, 2I2C, 2I2S, 18ADC(12BIT)	4M	540K	240	IEEE 802.11 b/g/n	4.2	\$15
BeagleBone Black	Sitara AM335x (32BIT)	4UART, 8PWM(12BIT),	2G	512M	1000	No	NO	\$70

		2SPI, 2I2C, 7ADC(12BIT), USB, HDMI						
Raspberry pi 3+	BCM2837B0 quad-core A53(64BIT)	1UART, 1SPI, 1I2C, DSI, CSI, HDMI, USB, ETHERNET	SD	1G	1400	IEEE 802.11 b/g/n/ac	4.2	\$80
Nvidia Jetson Nano	Quad-core ARM A57(64BIT)	UART, I2C, I2S, SPI, MIPI, CSI, DPHY, M.2, HDMI, ETHERNET	SD	4G	1400	NO	NO	\$100

En la fase de adquisición de datos, se realizaron las tomas de muestras de voltaje y corriente eléctrica de los electrodomésticos más comunes en el hogar, para realizar esta tarea se implementaron circuitos encargados de acoplar estas magnitudes físicas a los rangos de trabajo de la plataforma ESP32 y se implementó un sistema de almacenamiento mediante una memoria SD externa conectada a uno de los módulos SPI con los que dispone la plataforma de desarrollo.

En la adquisición de el voltaje AC de la línea doméstica se implementó un divisor de voltaje el cual realiza un escalamiento desde los 180 Volts pico de la red eléctrica domiciliaria hasta 3 Volts DC. El sistema resistivo utilizado se puede apreciar en la Ilustración 1.

Ilustración 1: Circuito de acoplamiento para el voltaje AC de la red eléctrica domiciliaria. Fuente: Autores.



Se realizó la implementación de un sistema de medición de corriente AC utilizando el dispositivo integrado ACS712 como se muestra en la Ilustración 2. El sensor de corriente entrega a su salida un voltaje entre 0 y 5 volts DC, fue necesario implementar el sistema resistivo que se evidencia en la Ilustración 3, el cual tiene como función realizar un escalamiento de 5 a 3.3 volts dado que este es el voltaje máximo que admite la plataforma ESP32 en cualquiera de sus pines.

Ilustración 2: Circuito integrado ACS712, modulo para la medición de corriente eléctrica.


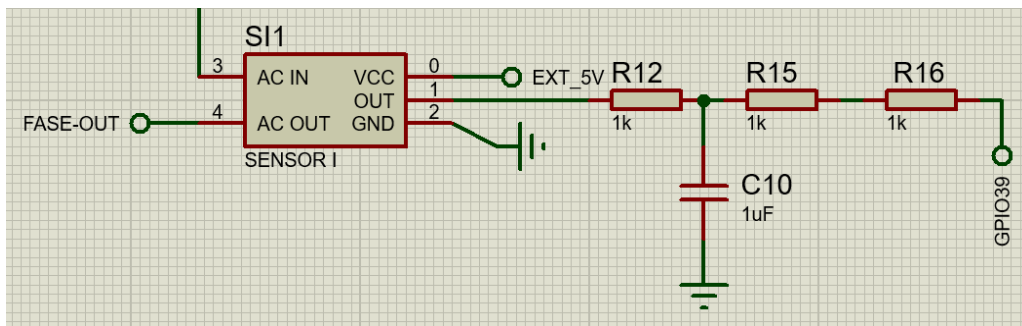


Ilustración 3: Circuito de acople para el sensor ACS712.



El ultimo requerimiento del sistema embebido, era dotarlo con la capacidad de realizar control de encendido y apagado sobre la carga que fuera conectada a él, para esto se diseñó e implementó un sistema de control, utilizando un dispositivo semiconductor triac BTA20, el cual tiene entre sus principales características la capacidad de conducir una corriente de hasta 20 amperios y soportar un voltaje máximo de 600 volts, en conjunto a este dispositivo se empleó un optoacoplador MOC3041, utilizado para separar eléctricamente los circuitos de control con la parte de alto voltaje AC. El sistema embebido completo incluye circuitos complementarios de alimentación, filtrado e indicación como se muestra en la Ilustración 4. El diseño final y funcional del sistema embebido se puede observar en la Ilustración 5.

Ilustración 4: Diseño esquemático del sistema embebido. Fuente: Autores.

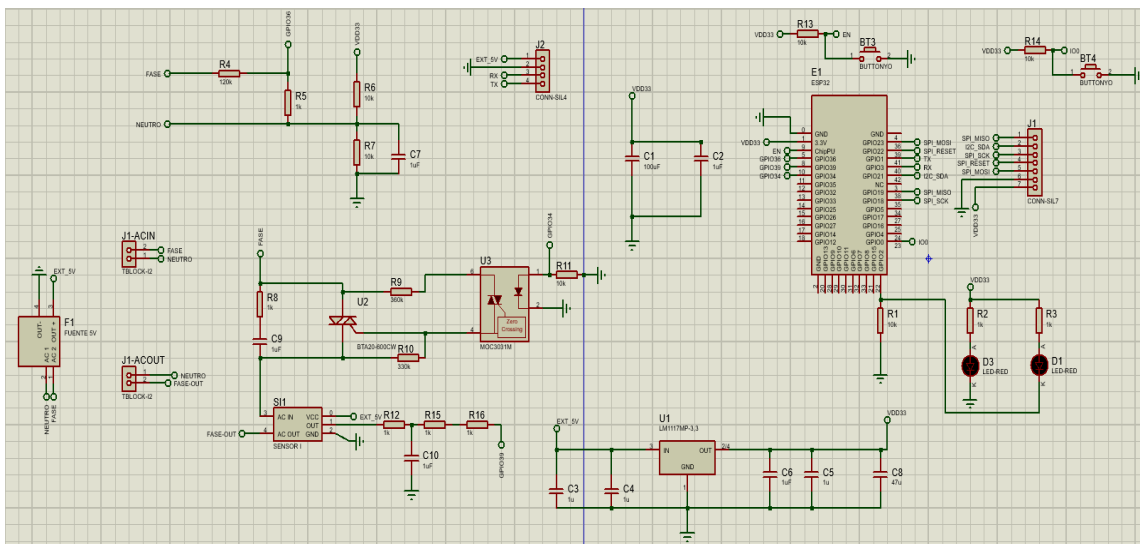



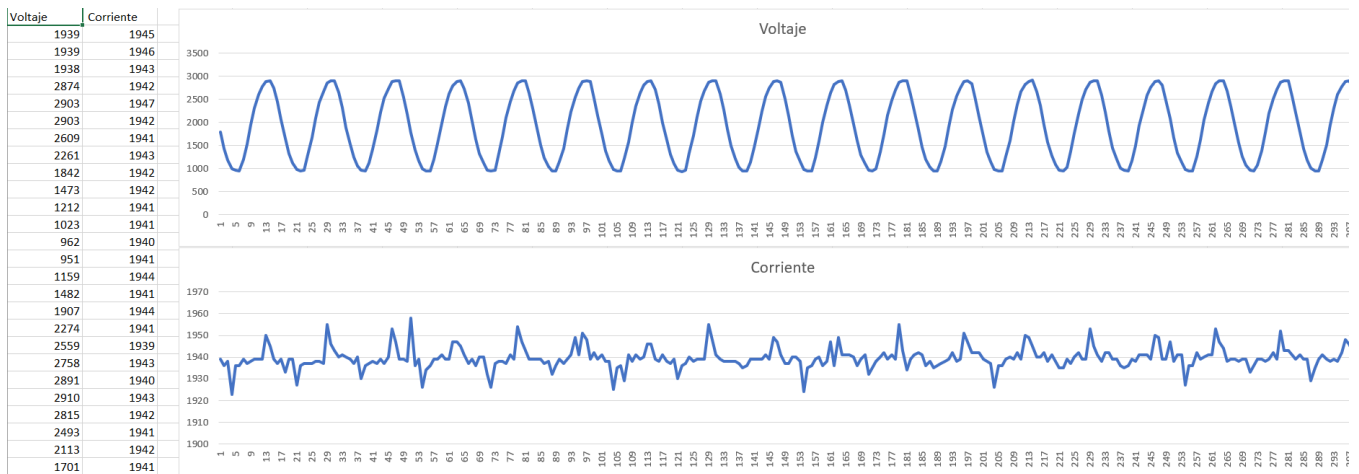
Ilustración 5: Sistema embebido utilizado en el proyecto. Fuente: Autores.



3.1.2 Software

La primera etapa del proyecto, consistió en recopilar datos de voltaje y corriente de los electrodomésticos más usados en el hogar, para cumplir este propósito se desarrolló el *hardware* necesario y se desarrolló un algoritmo, el cual tenía como propósito realizar el almacenamiento de esta información en una memoria SD, utilizando parámetros previamente especificados, estos parámetros son, tener la capacidad de generar un archivo de texto por cada electrodoméstico analizado, dicho archivo debía contener dos columnas, siendo la primera datos de voltaje instantáneo y la segunda columna datos de corriente instantánea, estos fueron tomados a una frecuencia fija de 1kHz. El proceso de toma de datos se realizó en dos eventos distintos, el inicio del programa indicaba en que archivo de texto se realizaría el guardado de datos, siendo los archivos separados en orden numérico, por ejemplo, para el primer archivo se genera el nombre “1.txt”, se conectaba el electrodoméstico y se configuraba en su modo de mínimo consumo o por defecto en estado de *standby*, luego se realizaba la toma de información por un periodo de 60 segundos, cuando este tiempo es alcanzado el sistema genera una indicación visual, el operario debe configurar el electrodoméstico en su modo de mayor consumo o funcionamiento pleno, y posteriormente presionar un pulsador, seguido este proceso el sistema realiza nuevamente el guardado de los datos por 60 segundos y el archivo se cierra, generando un estado de espera para un nuevo electrodoméstico. La información almacenada en la memoria SD se transfiere a una computadora para su visualización y análisis. En la Ilustración 6, se puede apreciar la información de voltaje y corriente de un cargador de teléfono móvil.

Ilustración 6: Grafica de voltaje y corriente instantáneas de un cargador de teléfono móvil. Fuente: Autores.



3.1.3 Adquisición de datos

La adquisición de datos de consumo y corriente de los electrodomésticos más usados en el hogar y sus características como modelo, fabricantes y tipo son presentados en la Tabla 2.

Tabla 2: Electrodomésticos utilizados en la etapa de adquisición de datos. Fuente: Autores.

N. Archivo	Equipo	Fabricante	Modelo	Consumo
celular	celular	alcatel	Pixi 4	16,5w
celular2	celular	samsung	s6 edge	55w
plancha	plancha	proctor silex	17210	1200w
computador	computador	pc smart	PCSGOB14P-C	65w
licuadora	licuadora	Imusa	lm378856	550w
portátil	portátil	Acer	es1-111	40w
portátil2	portátil	Asus	GL552	200w
celular3	celular	Huawei	p20 lite	55w
licuadora2	licuadora	Samurái	optimix	500w
celular4	celular	Huawei	mate20	22w
computador2	computador	Lenovo	ThinkStation	500w
televisor	televisor	LG	32ln520b	165w
televisor2	televisor	Samsung	un55j5300	150w
televisor3	televisor	Philips	32PFL3508	100w
plancha2	plancha	samurái	brio40	1200w
plancha3	plancha	Oster	4801L	1200w
portatil3	portátil	HP	8460p	65w
computador3	computador	HP	205 G3	150w
licuadora3	licuadora	Oster	4655	600w

Cada tipo de dispositivo es identificado con una etiqueta, la cual será utilizada por el sistema de clasificación, este etiquetado es presentado en la Tabla 3. Adicional a las etiquetas asociadas a cada electrodoméstico se crea una etiqueta con el nombre “Sin carga”, esta hace referencia a un dispositivo que se encuentra en modo de “Standby” o en modo de bajo consumo, se utiliza para identificar cuando un electrodoméstico no está siendo utilizado.

Tabla 3: Etiquetas asignadas a los distintos tipos de electrodomésticos. Fuente: Autores.

Nombre	Etiqueta
Sin carga	1
celular	2
plancha	3
computador	4
licuadora	5
portátil	6
televisor	7

3.2 Características eléctricas

Teniendo como información los datos de voltaje y corriente recolectados de los dispositivos eléctricos del hogar, se debe realizar una correcta diferenciación entre los diferentes tipos de dispositivos registrados, pero al analizar puramente esta información no es posible dar un correcto análisis, es necesario extraer características eléctricas de estas señales que brinden una información clave, que permita la clasificación de los distintos dispositivos del hogar. Se hizo uso de las siguientes características:

3.2.1 Potencia instantánea


La potencia instantánea, es una de las principales características en el análisis de sistemas eléctricos, la potencia instantánea se puede calcular haciendo el producto entre el voltaje y la corriente instantáneos, como se aprecia en la Ecuación 1. (J. Bollen & H. Gu, 2006)

$$P(t) = V(t) * I(t) \quad (1)$$

3.2.2 Potencia Máxima

Representa el valor máximo de potencia instantánea alcanzada por el sistema en un periodo de tiempo, en la Ilustración 7 se puede apreciar la representación gráfica de la potencia máxima.

Ilustración 7: Potencia máxima de una carga. Fuente: Autores.



3.2.3 Potencia distorsionada

La potencia distorsionada se encuentra relacionada al triángulo de potencias, que se construye con las potencias activa, reactiva y aparente (J. Bollen & H. Gu, 2006), la potencia distorsionada se evidencia en la Ecuación 2.

$$D = \sqrt{S^2 - P^2 - Q^2} \quad (2)$$

3.2.4 Factor de potencia

El factor de potencia, se define como la relación entre la potencia activa y la potencia aparente (J. Bollen & H. Gu, 2006), esta se puede apreciar en la Ecuación 3.

$$Fp = \frac{P}{S} \quad (3)$$

3.2.5 Potencia reactiva

La potencia reactiva, aparece en un sistema que incluye bobinas o condensadores, este tipo de potencia no genera trabajo debido a que su valor medio es nulo (J. Bollen & H. Gu, 2006), para calcular su valor se hace uso de la Ecuación 4.

$$Q = S * \sin(\phi) \quad (4)$$

3.2.6 Potencia aparente

Es la potencia total consumida por la carga y se obtiene como el producto de los valores eficaces de voltaje y corriente, está se define como la suma vectorial de las potencias activa y reactiva (J. Bollen & H. Gu, 2006), se puede apreciar en la Ecuación 5.

$$S = V_{Rms} * I_{Rms} \quad (5)$$

3.2.7 Ángulo de desfase

El ángulo de desfase es la representación angular del factor de potencia, y se puede obtener hallando el coseno inverso del factor de potencia (J. Bollen & H. Gu, 2006), esto se representa en la Ecuación 6.

$$\phi = \cos^{-1}(Fp) \quad (6)$$

3.2.8 Distorsión armónica total

La distorsión armónica total es generalmente utilizada como un indicador de la calidad de la energía y se define como la energía presente de una señal en frecuencias no fundamentales (J. Bollen & H. Gu, 2006), y se describe en la Ecuación 7.

$$THD = \frac{\sqrt{\sum_{h=2}^H V_h^2}}{V_1} \quad (7)$$

3.2.9 Varianza de la corriente

Se define como la dispersión de una variable sobre su valor medio, es un indicador de valores con altas tasas de cambio respecto al tiempo (J. Bollen & H. Gu, 2006), y su se usa la Ecuación 8.

$$\sigma_n^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})^2 \quad (8)$$

3.2.10 Corriente eficaz

La corriente eficaz se describe como el valor de corriente continua que debería transitar por una resistencia para generar la misma energía calórica que una corriente AC, es también conocido como valor cuadrático medio y puede ser calculado a cualquier señal periódica mediante la Ecuación 9 (J. Bollen & H. Gu, 2006).

$$I_{Rms} = \sqrt{\frac{1}{T} \int_0^T i^2(t) dt} \quad (9)$$

3.3 Máquinas de aprendizaje

Las máquinas de aprendizaje son técnicas computacionales utilizadas para desarrollar algoritmos de predicción con base a muestras de datos, existen distintas técnicas de clasificación las cuales se dividen en dos clases. Las máquinas de aprendizaje no supervisadas y las supervisadas, las primeras son aquellas que realizan un proceso de agrupación y separación de los datos de entrada. Las máquinas de aprendizaje supervisadas son las que generan una función que relaciona los datos de salida vs los datos entrada, en este tipo de clasificadores se entregan tanto los datos de entrada como los de salida y el sistema busca generar reglas que describan una igualdad entre los datos (H. Witten, Eibe, A. Hall, & J. Pal, 2017).

En el proceso de entrenamiento de todos los métodos de clasificación utilizados, se realizó la verificación cruzada (del

inglés, *Cross-Validation*), definida por (Zhang & Yang, 2015), como el proceso de realizar una separación aleatoria de los datos de entrada y sus correspondientes salidas para hacer uso de una parte de los datos para el entrenamiento del sistema y con los datos restantes realizar su validación, con este proceso lo que se busca es entrenar el sistema de predicción varias veces con los datos en diferente orden y verificar que para cada caso el sistema tenga una tasa de acierto aceptable. En la implementación se realizaron análisis de tres tipos de máquinas de aprendizaje, que presentarán facilidad en su desarrollo en un sistema embebido, los tipos de máquinas utilizadas fueron: Redes neuronales, arboles de decisión y K vecinos más cercanos, a continuación, se describen los principios de funcionamiento de estas máquinas:

3.3.1 Redes Neuronales Artificiales

Las redes neuronales artificiales ANN (del inglés, *Artificial Neural Network*) son una abstracción matemática del proceso de comunicación y generación de información de las redes neuronales físicas. Un tipo de implementación de redes neuronales artificiales ampliamente utilizadas son los perceptrón multicapa MLP (del inglés *Multi-Layer Perceptron*), esta son una evolución de la red neuronal de capa simple, su funcionamiento se basa en el uso de una serie de capas ocultas, lo cual es ideal para la resolución de problemas no lineales (Chen, Liu, Shi, Xu, & Xu, 2018), una MLP se conforma mínimo por 3 capas, la primera es la capa de entrada, en esta se reciben los datos a ser utilizados por la ANN, la segunda capa hace parte del grupo de las capas ocultas siendo necesario tener por lo menos una capa de ese tipo y por último se tiene la capa de salida la cual entrega los datos generados por la ANN (Zhang, Wang, & Liu, 2014).

La **¡Error! No se encuentra el origen de la referencia.**0 es una representación matemática de una red neuronal, en donde x son las entradas de la neurona, w es la matriz de los pesos sinápticos y b es el valor de las vías. (Khosrojerdi, Vakili, & Kalhor, 2016)

$$y = f(x \cdot w + b) \quad (10)$$

3.3.2 Máquinas de soporte de vectores

Las máquinas de soporte vectorial (SVM, del inglés *Support Vector Machines*) pertenecen al grupo de los clasificadores lineales debido a que realizan una separación lineal de los datos ya sea en el plano de características original o en un espacio transformado (Carmona Suárez, 2014)

3.3.3 K-vecinos más próximos

El sistema de clasificación de los k-vecinos más cercanos KNN (del inglés *k-nearest neighbors*) utiliza la medida de distancia euclidiana para definir la pertenencia de un nuevo elemento al clasificador. Este algoritmo almacena todas las muestras utilizadas en el proceso de entrenamiento y luego realiza el cálculo de distancia del nuevo elemento con relación a los almacenados, el resultado lo ordena de menor a mayor y dependiendo del número de vecinos definidos previamente, por votación de las clases los N vecinos se establece la clase a la que pertenece la nueva muestra. En el proceso de validación para este sistema de clasificador se utilizaron una cantidad de 3,5 y 7 vecinos.

3.3.4 Árbol de Decisión

El árbol de decisión basa su funcionamiento en generar una separación de los datos mediante técnicas estadísticas y la asignación umbrales para las características de entrada con los cuales sea posible generar un sistema de clasificación exitoso. (referencia)

3.4 Implementación del sistema de caracterización de cargas en la plataforma embebida

La implementación del sistema de caracterización de cargas consiste en dotar al sistema embebido con la capacidad de tomar datos de voltaje y corriente para realizar la extracción de características eléctricas, utilizando las ecuaciones anteriormente definidas, haciendo uso de estas características eléctricas se realiza el proceso de generar un resultado mediante el uso de la ANN previamente entrenada, el entrenamiento se realiza en un computador de escritorio. Cuando

el proceso de entrenamiento finaliza se transfiere la información de la matriz de pesos sinápticos, valor de las bias, topología de la red y los valores de normalización de las características. La Tabla 4 presenta el espacio de memoria requerido para la implementación de una red neuronal tipo MLP en un sistema embebido.

Tabla 4: Espacio de memoria para una red neuronal tipo MLP.

Campo	Descripción	Tamaño (bytes)	Tipo de dato
Ts	Tiempo de muestreo	2	long
-----Space for pre/post-processing parameters-----			
totalLayers = k	Número total de la k -ésima capa excluyendo la capa de entrada	1	byte
totalNeurons = n	Número total de neuronas excluyendo las neuronas de entrada $n = \sum_{i=1}^k m[i]$	1	byte
m[0] ... m[k]	Número de neuronas por cada capa	$k+1$	byte
f[1] ... f[k]	Función de activación por capa	k	byte
x[1] ... x[m0]	Entradas a la red neuronal	$4*m[0]$	float
L[1].y[1] ... L[1].y[m1] ... L[k].y[1] ... L[k].y[m[k]]	Capa de salida	$4*n$	float
L[1].b[1] ... L[1].b[m1] ... L[k].b[1] ... L[k].b[m[k]]	<i>Bias</i>	$4*n$	float
L[1].w[1, 1] ... L[1].w[m[1],m[0]] ... L[k].w[1,1] ... L[k].w[m[k],m[k-1]]	Pesos	$4 \sum_{i=1}^k (m[i] \cdot m[i - 1])$	float

4. RESULTADOS Y DISCUSIÓN

La Tabla 5 presenta los valores promedio de cada una de las características de todos los electrodomésticos, el valor entre paréntesis corresponde a la desviación estándar del valor de cada característica. Las leyendas utilizadas en la tabla corresponden a: Potencia distorsionada (CosPhi), Factor de potencia (Fp), Potencia activa (P), Angulo de desfase (Phi), Potencia máxima (PMax), Potencia reactiva (Q), Potencia aparente (S), Distorsión armónica total (TDH), Varianza de la


corriente (I_{Var}), Corriente eficaz (I_{RMS}).

Tabla 5: Promedio y desviación estándar de las características eléctricas utilizadas. Fuente: Autores.

Característica/ Dispositivo	CosPhi(W)	Fp	P(W)	Phi (°)	P _{Max} (W)	Q(VAR)	S(VA)	TDH	Ivar(A ²)	I _{RMS} (A)
Celular	0,6208 (0.059)	0,6048 (0.058)	8,1712 (3.384)	51,4925 (4.331)	73,0285 (21.919)	10,1602 (3.431)	13,2062 (4.762)	0,2013 (0.126)	0,0150 (0.009)	0,1165 (0.042)
Plancha	0,4918 (0.447)	0,4858 (0.453)	346,9069 (362.266)	50,9783 (37.718)	822,3436 (748.293)	91,1069 (118.537)	377,9307 (362.121)	0,4122 (0.494)	26,8314 (28.145)	3,7319 (3.593)
Computador	0,8599 (0.053)	0,8519 (0.022)	26,5825 (2.809)	30,7677 (4.773)	90,4836 (14.000)	15,8123 (2.160)	31,1428 (2.514)	0,0589 (0.137)	0,0658 (0.010)	0,2560 (0.020)
Licuada	0,4229 (0.048)	0,4163 (0.054)	61,3691 (10.985)	64,9412 (3.039)	410,8598 (150.090)	132,1005 (6.038)	146,2342 (9.398)	0,1565 (0.115)	1,9502 (0.234)	1,3939 (0.087)
Computador Portátil	0,6303 (0.053)	0,6186 (0.053)	30,5956 (4.384)	50,8136 (3.992)	261,2086 (20.992)	37,9482 (1.348)	49,2270 (3.101)	0,1836 (0.070)	0,1993 (0.050)	0,4430 (0.056)
Televisor	0,7678 (0.209)	0,7583 (0.216)	39,2682 (20.464)	34,2822 (21.693)	171,5152 (18.479)	21,0711 (7.726)	47,9799 (13.323)	0,1282 (0.144)	0,2042 (0.108)	0,4344 (0.125)
Bajo Consumo	0,1903 (0.106)	0,1696 (0.099)	3,9099 (12.4971)	78,8888 (6.999)	54,7115 (62.848)	10,1749 (21.781)	11,1255 (25.125)	0,5331 (0.673)	0,0667 (0.253)	0,1022 (0.237)

Los datos presentan una alta desviación lo que hace necesario verificar la separabilidad de las clases, para ello se evaluó el análisis de componentes principales PCA (del inglés *Principal Component Analysis*). La Ilustración 8 muestra los resultados de la representación de las componentes principales de los datos utilizados para este estudio, de esta se puede concluir que los datos presentan un bajo nivel de separación entre clases, lo que indica la necesidad del uso de técnicas de inteligencia computacional que permitan un proceso de clasificación exitoso.

Ilustración 8: Resultado del análisis de componentes principales. Fuente: Autores.



Se realizó el entrenamiento de un clasificador tipo Árbol de Decisiones, debido a que este algoritmo presenta un bajo costo computacional, su implementación se realizó utilizando condicionales y operaciones matemáticas básicas. Al realizarse la validación cruzada se obtiene como resultado una tasa de error del 23.4%. Se implementa el Árbol de decisiones en el sistema embebido y se verifica su funcionamiento obteniendo como resultado, que el sistema no tiene la capacidad de realizar la correcta caracterización de los electrodomésticos que presentan fuertes variaciones en sus características eléctricas, debido a que este clasificador utiliza la definición de umbrales por ende no tiene la capacidad de identificar correctamente elementos que producen altos niveles de ruido y tampoco puede utilizar características que tengan un alto nivel de variación como lo son la potencia reactiva y la varianza de la corriente.

Se entrenó un clasificador k-Vecinos más cercanos KNN. Este clasificador es un sistema mucho más robusto que el árbol de decisiones y presentó una tasa de error promedio de 1.1538% y una desviación estándar de 0.7278 %, sin embargo, en su implementación se requiere 38KB de memoria volátil y tiempos de ejecución muy largos lo que imposibilita su implementación en un sistema embebido.

Se realizó el proceso de entrenamiento de la ANN y se generó una lista de valores de los pesos sinápticos, las bias, los valores para la normalización de los datos y las funciones de activación. Se utilizaron diferentes topologías de red, lo cual implicó diferentes capacidades en el tamaño de bytes a utilizar número de neuronas a utilizar, la Tabla 6 presenta los resultados de las diferentes topologías entrenadas. La topología con dos capas ocultas, cada una con 10 neuronas, brinda un nivel de error promedio de 2.051% y una desviación estándar de 1.2385%, sin comprometer en gran medida la memoria del sistema y los tiempos de ejecución. Se realizó un ajuste al clasificador KNN, aproximando el valor de memoria volátil que consume a los valores de uso de la red neuronal artificial, esto con el fin de apreciar en igualdad de condiciones cual clasificador presenta un mayor rendimiento, se encontró que el KNN presenta niveles de error superiores a la red neuronal artificial, esta información se muestra en la Tabla 7.

Tabla 6: Pruebas realizadas a diferentes topologías de redes neuronales. Fuente: Autores.

Topología	Neuronas	Error Promedio	Tamaño(bytes)	Desviación Estándar	Tiempo (us)
7	7	5,512820513	514	4,91174206	110
10	10	8,333333333	664	5,38020441	157

10 4	14	3,717948718	836	3,27975792	215
10 8	18	7,051282051	1044	7,93192786	277
10 10	20	2,051282051	1148	1,23857921	310
10 4 1	15	23,71794872	852	36,5790498	232
10 4 4	18	13,20512821	936	28,5337627	266
10 4 8	22	7,179487179	1048	7,38216167	326
10 4 10	24	5,641025641	1110	4,01800317	366

Tabla 7: Comparación entre diferentes sistemas de clasificación. Fuente: Autores.

Clasificador	Error promedio	Desviación estándar	Tamaño (Bytes)
Árbol de Decisión	23.4%	1.3241	100
KNN	1.1538%	0.7278	34320
KNN (Ajustado)	83.8333%	18.6596	1232
Red Neuronal	2.051282051%	1.23857921	1148

La red neuronal artificial implementada en el sistema embebido permitió evaluar los tiempos de establecimiento de la señal de los electrodomésticos conectados, la Tabla 8 muestra estos tiempos.

Tabla 8: Tiempo promedio para la generación de un resultado valido. Fuente: Autores.

Dispositivo	Tiempo (S)
Celular	3
Portátil	2
computador	2
televisor	3
Plancha	2
licuadora	9

La gestión de demanda planteado para su uso en un sistema de domótica inteligente, con la capacidad de reconocer que electrodomésticos hay conectados al sistema y poder ejercer acciones de control que garanticen un bajo consumo eléctrico, sin realizar afectaciones mayores al usuario, requiere una caracterización e identificación correcta de las cargas eléctricas conectadas al sistema. Para evaluar el sistema propuesto se realiza una simulación basada en el tiempo que permanecen los dispositivos conectados a la red eléctrica y cuál sería el consumo sin acciones de gestión de carga lo que denominamos consumo en estado normal vivienda, haciendo referencia a una vivienda sin un sistema de domótica, una gestión de carga basada en los sistemas domóticos tradicionales y una gestión de carga, donde se usa la caracterización de los electrodomésticos como base para una gestión de demanda inteligente. Los resultados de esta simulación y la correspondiente reducción en términos de producción de dióxido de carbono son presentados en la Tabla 9. Donde se verán reflejados el consumo eléctrico y stdbay en kilo vatios de cada uno de los dispositivos utilizados. En los sistemas simulados se incluyen los consumos eléctricos de los dispositivos de monitoreo y gestión de demanda.

Tabla 9: Resultado de la simulación del consumo eléctrico mensual en una vivienda sin sistema domótico, con un sistema de control tradicional y un sistema inteligente con caracterización de cargas. Fuente: Autores.

Nombre	Consumo Dispositivo (KW/h)	STDBAY Dispositivo (KW/h)	Consumo en estado normal vivienda	Consumo domótico tradicional	consumo caracterización de cargas KW/mes
--------	----------------------------	---------------------------	-----------------------------------	------------------------------	--

			KW/mes (CO2-Kg)	KW/mes (CO2-Kg)	(CO2-Kg)
Celular	0,037125	0,004	194,94 (72,1275)	114,75 (42,455)	53,964 (19,965)
Plancha	1,2	0	207,36 (76,72)	0	0
Computadora	0,065	0,005	367,2 (135,86)	367,2 (135,86)	281,16 (104,03)
Licuada	0,55	0	39,6 (14,65)	0	0
Portátil	0,12	0,004	535,68 (198,2)	276,48 (102,295)	259,344 (95,955)
Televisor	0,1575	0,006	1412,64 (522,675)	732,24 (270,93)	286,632 (106,055)
Sistema de Monitoreo	0,0007425	825x10 ⁻¹¹	0(0)	0,5346(0.2)	0,26730297(0.1)
Total			2757.42	1491.2046	881.37

El uso de la caracterización de cargas en un sistema domótico inteligente brinda la posibilidad de generar señales de alarma sobre aquellos dispositivos que no pueden ser simplemente desconectados, como computadores de sobremesa o generar alarmas sobre dispositivos que no deberían funcionar por periodos prolongados de tiempo, como la licuadora o la plancha para ropa. La implementación de un sistema domótico utilizando la capacidad de caracterizar e identificar cargas requiere la creación de un ecosistema de toma corrientes conectados en una red tipo MESH, aprovechando las capacidades de conectividad WI-FI y bluetooth de las que dispone la plataforma de desarrollo ESP32.

En la tabla presentada anteriormente se toma como referencia el total consumido en cada uno del caso y así realizar una comparativa de ahorro energético del sistema domótico con caracterización de cargas con respecto a una vivienda y a una con un sistema domótico tradicional.

Al realizar esta comparativa se obtuvo que el sistema de caracterización de cargas tiene un ahorro del 69% respecto a una vivienda normal y un 23% respecto a un sistema domótico sin caracterización de cargas. Esto valores se obtienen realizando la ecuación 11.

$$R = \frac{Total * 100}{257.42} \quad (11)$$

5. CONCLUSIONES

La implementación de herramientas matemáticas y estadísticas, como lo son las máquinas de aprendizaje para el proceso de caracterización de cargas eléctricas requieren de una adecuada definición y selección de especificaciones técnicas y económicas para la implementación en sistemas embebidos o sistemas de desarrollo de bajo costo.

Se implementó algoritmo que permitió ajustar redes neuronales artificiales de hasta 50 neuronas en un sistema embebido de bajo costo para clasificación una tasa de error de 2%, que posibilita la gestión de demanda eléctrica en sistema domótico con capacidad de caracterización de cargas con altos niveles de ahorro energético.

Los sistemas de domótica tradicionales basan su funcionamiento en acciones tomadas completamente por el usuario sin ningún tipo de toma de decisiones de forma autónoma, la caracterización de cargas eléctricas brinda la oportunidad de desarrollar sistemas domóticos inteligentes que ejecuten acciones avanzadas de control sobre una vivienda.

En comparativa a los sistemas domóticos tradicionales se puede lograr un ahorro de hasta el 23% en lo que a gestión de consumo energético se refiere y si se compara con una vivienda sin ningún tipo de control o gestión de demanda

energética, se puede lograr hasta un 69% de ahorro energético.

6. REFERENCIAS

- Ammari, T., Kaye, J., Y. Tsai, J., & Bentley, F. (2019). Music, Search, and IoT: How People (Really) Use Voice Assistants. *ACM Trans. Comput.-Hum.*
- Banu, B., Merlin, S., & Suhitha, S. (2018). Domotics using labview. *International Journal of Research.*
- Bouazzaoui Cherraqi, E., & Maach, A. (2018). Load Signatures Identification Based on Real Power Fluctuations. *Springer International Publishing.*
- Carmona Suárez, E. J. (2014). Tutorial sobre Máquinas de Vectores Soporte (SVM). *UNED.*
- Chen, X., Liu, G., Shi, J., Xu, J., & Xu, B. (2018). Distilled Binary Neural Network for Monaural Speech Separation. *IJCNN.*
- Ciabattoni, L., Ferracuti, F., Ippoliti, G., Longhi, S., & Turri, G. (2016). IoT Based Indoor Personal Comfort Levels Monitoring. *ICCE.*
- Dobrescu, L. (2014). Domotic Embedded System. *ECAI.*
- Escobar Gallardo, E., & Villazón, A. (2018). SISTEMA DE MONITOREO ENERGÉTICO Y CONTROL DOMÓTICO BASADO EN TECNOLOGÍA "INTERNET DE LAS COSAS". *INVESTIGACIÓN & DESARROLLO.*
- García Ortiz, M. (2016). Adaptación y Aplicación de la Transformada de Hilbert-Huang a Sistemas Eléctricos: Aplicaciones en el Estudio de la Gestión de la Demanda y Caracterización de Transitorios. *Springer.*
- García, V. H., & Vega, N. (2018). Low Power Sensor Node Applied to Domotic. *Springer Nature Switzerland.*
- Guerard, G., Levy, L.-N., & Pousseur, H. (2018). Multi-agent Model for Domotics and Smart Houses. *SCITEPRESS.*
- H. Witten, I., Eibe, F., A. Hall, M., & J. Pal, C. (2017). *Data Mining: Practical Machine Learning Tools and Techniques.* Cambridge: Elsevier.
- Hassanpour, V., Rajabi, S., Shayan, Z., Hafezi, Z., & Arefi, M. M. (2017). Low-Cost Home Automation Using Arduino and. *ICCLA.*
- J. Bollen, M. H., & H. Gu, I. Y. (2006). *Signal Processing of Power Quality DISTURBANCES.* Danvers: IEEE PRESS SERIES ON POWER ENGINEERING.
- Khosrojerdi, S., Vakili, M., & Kalhor, K. (2016). Thermal conductivity modeling of graphene nanoplatelets/deionized water nanofluid by MLP neural network and theoretical modeling using experimental results. *Elsevier.*
- Morón, C., Payán, A., García, A., & Bosquet, F. (2016). Domotics Project Housing Block. *MDPI.*
- Moya CH., F. D. (2018). A Mathematical Model for the Optimal Scheduling of Smart Home Electrical Loads. *WSEAS TRANSACTIONS on POWER SYSTEMS.*
- Ovalles, F. O., Bolivar, A. E., & Rodriguez, A. J. (2018). Use of an embedded system with wifi technology for domotic. *IOP Publishing.*
- Siswanto, A., Katuk, N., & Ku-Mahamud, K. R. (2016). Biometric Fingerprint Architecture for Home Security System. *LACE.*
- Taryudi, Bagas Adriano, D., & Ciptoning Budi, W. A. (2018). Iot-based Integrated Home Security and Monitoring System. *IOP Conf. Series: Journal of Physics.*

Toro Betancur, V. (2017). ALGORITMO DE ESTIMACIÓN DE PARÁMETROS Y MODULACIÓN DE UNA SEÑAL RECIBIDA POR UN SDR. *EAFIT*.

Zhang, H., Wang, Z., & Liu, D. (2014). A Comprehensive Review of Stability Analysis of Continuous-Time Recurrent Neural Networks. *IEEE TRANSACTIONS ON NEURAL NETWORKS AND LEARNING SYSTEMS*.

Zhang, Y., & Yang, Y. (2015). Cross-Validation for Selecting a Model Selection Procedure. *Journal of Econometrics*.