



REPÚBLICA DEL ECUADOR

Escuela Politécnica Nacional

" E S C I E N T I A H O M I N I S S A L U S "

La versión digital de esta tesis está protegida por la Ley de Derechos de Autor del Ecuador.

Los derechos de autor han sido entregados a la "ESCUELA POLITÉCNICA NACIONAL" bajo el libre consentimiento del (los) autor(es).

Al consultar esta tesis deberá acatar con las disposiciones de la Ley y las siguientes condiciones de uso:

- Cualquier uso que haga de estos documentos o imágenes deben ser sólo para efectos de investigación o estudio académico, y usted no puede ponerlos a disposición de otra persona.
- Usted deberá reconocer el derecho del autor a ser identificado y citado como el autor de esta tesis.
- No se podrá obtener ningún beneficio comercial y las obras derivadas tienen que estar bajo los mismos términos de licencia que el trabajo original.

El Libre Acceso a la información, promueve el reconocimiento de la originalidad de las ideas de los demás, respetando las normas de presentación y de citación de autores con el fin de no incurrir en actos ilegítimos de copiar y hacer pasar como propias las creaciones de terceras personas.

Respeto hacia sí mismo y hacia los demás.

ESCUELA POLITÉCNICA NACIONAL

FACULTAD DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA

DISEÑO E IMPLEMENTACIÓN DE UN SISTEMA DE MONITOREO DE CARGA NO INTRUSIVO PARA EL SECTOR RESIDENCIAL

**TRABAJO DE TITULACIÓN PREVIO A LA OBTENCIÓN DEL TÍTULO DE
INGENIERO EN INGENIERÍA ELECTRÓNICA Y CONTROL**

JOSÉ LUIS LÓPEZ GUAÑUNA

DIRECTOR: DR. OSCAR EDUARDO CAMACHO QUINTERO

Quito, Octubre 2020

AVAL

Certifico que el presente trabajo fue desarrollado por José Luis López Guañuna, bajo mi supervisión.

DR. OSCAR CAMACHO
DIRECTOR DEL TRABAJO DE TITULACIÓN

DECLARACIÓN DE AUTORÍA

Yo, José Luis López Guañuna, declaro bajo juramento que el trabajo aquí descrito es de mi autoría; que no ha sido previamente presentado para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento.

A través de la presente declaración dejo constancia de que la Escuela Politécnica Nacional podrá hacer uso del presente trabajo según los términos estipulados en la Ley, Reglamentos y Normas vigentes.

JOSÉ LUIS LÓPEZ GUAÑUNA

DEDICATORIA

Todo trabajo que se realiza tiene una fuente de inspiración, un por qué que nos impulsa a cumplir cualquier tarea por más tediosa o estresante que sea. En mi caso, esta inspiración ha sido mi familia, que con cariño y unidad me ha ayudado a superar todos los retos que esta vida me tenía. En especial este trabajo va dedicado a mi padre y mi madre, que con su humilde ejemplo me enseñaron a no rendirme jamás, a luchar por lo que quiero. Así también, este trabajo va dedicado a mis hermanos, que siempre han sido un apoyo cuando los he necesitado.

AGRADECIMIENTO

Quisiera empezar agradeciendo al Doctor Oscar Camacho, que siempre ha estado presto a ayudarme en la culminación exitosa de este proyecto. Así también quisiera agradecer a lo que la gente llama Dios, el Todo, el que hace que todo llegue a ser, por la oportunidad de llegar a ser consciente y disfrutar de la existencia. Finalmente, agradezco a mi yo de hace unos diez años, que nunca se rindió, porque siempre supo que todo lo malo iba a acabar y vendrían cosas mejores.

ÍNDICE DE CONTENIDO

AVAL.....	I
DECLARACIÓN DE AUTORÍA	II
DEDICATORIA	III
AGRADECIMIENTO	IV
ÍNDICE DE CONTENIDO.....	V
RESUMEN.....	VI
ABSTRACT.....	VII
1. INTRODUCCIÓN.....	1
1.1 OBJETIVOS.....	1
1.2 ALCANCE	2
1.3 MARCO TEÓRICO	2
1.3.1 MÓDULO DE ADQUISICIÓN DE DATOS.....	5
1.3.2 EXTRACCIÓN DE CARACTERÍSTICAS.....	6
2. METODOLOGÍA.....	18
2.1 MEDIDOR DE PARÁMETROS ELÉCTRICOS.....	18
2.1.1 SELECCIÓN DEL CHIP MEDIDOR DE PARÁMETROS ELÉCTRIOS	18
2.1.2 DISEÑO MEDIDOR PARÁMETROS ADE7753	19
2.1.3 CALIBRACIÓN DEL MEDIDOR DE PARÁMETROS ELÉCTRICOS.....	22
2.2 SOFTWARE DE CLASIFICACIÓN	25
2.2.1 RED NEURONAL ARTIFICIAL USANDO PYTHON	26
3. RESULTADOS Y DISCUSIÓN	33
4. CONCLUSIONES Y RECOMENDACIONES	44
3.1. CONCLUSIONES	44
3.2. RECOMENDACIONES	45
5. REFERENCIAS BIBLIOGRÁFICAS.....	46
ANEXOS.....	47

RESUMEN

El consumo de los recursos naturales se ha incrementado de manera exponencial desde la revolución industrial, y la gran mayoría de estos no son ilimitados. Esto ha conllevado a desarrollar distintas tecnologías que nos permitan evitar el gasto ineficiente de recursos. Dentro de estas tecnologías, tenemos la de monitoreo de carga no intrusiva (NILM por sus siglas en inglés). Básicamente ésta se basa en el análisis de las características de consumo energético de los distintos dispositivos domiciliarios. Este análisis nos permite desagregar el consumo energético de un hogar, tomando mediciones de las características de consumo en la acometida del mismo, con métodos no intrusivos. Con este fin, esta tesis se ha centrado en usar redes neuronales artificiales para determinar si un dispositivo domiciliario está encendido o no. Esto se logra entrenando la red neuronal con mediciones previas de los patrones de consumo de los distintos aparatos a identificar su estado. Y para que el usuario pueda tener una retroalimentación sencilla y móvil de toda la información extraída, se ha desarrollado una aplicación Android que indica tanto el estado del dispositivo, como un aproximado de su consumo de corriente y potencia activa.

PALABRAS CLAVE: NILM, no intrusiva, desagregar, monitoreo, energía

ABSTRACT

The consumption of natural resources has increased exponentially since the industrial revolution, and the vast majority of these are not unlimited. This has led to the development of various technologies that prevent us from avoiding inefficient spending of resources. Within these technologies, we have non-intrusive load monitoring (NILM). Basically, this is based on the analysis of the energy consumption characteristics of the different household devices. This analysis allows us to disaggregate the energy consumption of a home, to take measures of the consumption characteristics in its connection, with non-intrusive methods. To this end, this thesis has focused on using artificial neural networks to determine if a home device is turned on or not. This is achieved by training the neural network with previous measurements of the consumption patterns of the different devices to identify their state. And so that the user can have a simple and mobile feedback of all the extracted information, an Android application has been developed that indicates both the status of the device and an approximate of current consumption and active power.

KEYWORDS: NilM, unbundled, monitoring, non-intrusive, energy

1. INTRODUCCIÓN

El incremento de consumo energético en las últimas décadas ha sido exponencial, por lo cual la conservación de energía ha despertado el interés científico. Investigadores están desarrollando soluciones tecnológicas direccionadas a solucionar esta problemática. Tan solo en la unión europea cerca del 30% de energía usada es direccionada al sector residencial. Este consumo sigue creciendo junto con los efectos ambientales negativos, mientras los recursos energéticos son limitados. Tanto el cambio climático como la economía de un país son directamente afectados por el incremento de consumo energético.

Estudios han sugerido que la realimentación de la información de consumo eléctrico ya sea por métodos directos (información en tiempo real del consumo de los dispositivos) o indirectos (facturas mensuales) al usuario dan como resultado un máximo de ahorro energético. Por este motivo se han empezado a desarrollar desde hace algunas décadas, sistemas de monitoreo de carga tanto intrusivos como no intrusivos.

Un sistema de monitoreo de carga no intrusiva se describe como un conjunto de dispositivos que, mediante el análisis y medición de los parámetros eléctricos en la acometida de una residencia, permiten la desagregación de la potencia total consumida, indicando de igual manera el estado de los dispositivos en el interior del domicilio (ON-OFF) [1]. Esta tecnología fue ideada en la década de los 80's y 90's por George W. Hart, PhD.

Inicialmente se le nombro como no intrusiva para recalcar la no necesidad de intromisión en cada uno de los dispositivos a analizar, ya que únicamente se requiere sensores en la entrada de energía al domicilio. Dichos sensores permiten la recolección de los datos de corriente y voltaje, que posteriormente son analizados por un sistema computacional.

1.1 OBJETIVOS

El objetivo general de este Proyecto Técnico es:

- Diseñar e implementar un sistema de monitoreo de carga no intrusivo para el sector residencial

Los objetivos específicos del Proyecto Técnico son:

- Estudiar el funcionamiento de un sistema de monitoreo de carga no intrusivo (Non-Intrusive Load Monitoring-NILM).

- Diseñar e implementar un sistema de medición de corriente alterna monofásico basado en el criterio de monitoreo de carga no intrusivo para la acometida de un sistema residencial.
- Realizar mediciones y análisis del comportamiento de consumo de al menos cinco cargas eléctricas residenciales.
- Identificar al menos cinco cargas eléctricas conectadas en una residencia, para determinar su consumo energético y costo estimado de energía consumida.
- Desarrollar una aplicación para sistema operativo Android que permita el monitoreo y visualización en línea del consumo de potencia y energía de las cargas eléctricas de una residencia.

1.2 ALCANCE

- Adiestrarse en el funcionamiento de un sistema de monitoreo de carga no intrusivo (Non-Intrusive Load Monitoring-NILM).
- Estudiar el diseño e implementación de un sistema de medición de corriente alterna monofásico basado en el criterio de monitoreo de carga no intrusivo para la acometida de un sistema residencial.
- Desarrollar una red neuronal artificial usando librerías de Python para lograr la identificación de al menos cinco cargas eléctricas conectadas en una residencia, para estimar su consumo energético y costo estimado de energía consumida.
- Estudiar el desarrollo de aplicaciones Android, para implementar una que permita el monitoreo y visualización en línea del consumo de potencia y energía de las cargas eléctricas de una residencia, así como históricos de consumo.

1.3 MARCO TEÓRICO

Partiendo de la premisa que la señal en la entrada de la residencia es la suma de las señales consumidas por los diferentes aparatos, donde para el caso de la potencia activa matemáticamente se puede de finir como:

$$P(t) = p_1(t) + p_2(t) + \dots + p_n(t) \quad (1.1)$$

donde p_i es el consumo de potencia de un dispositivo individual que contribuye a la medida agregada y n es el número total de aparatos encendidos en un periodo de tiempo t [2]. La tarea del sistema NILM muchas veces se centra en la descomposición de $P(t)$ en la señal de potencia específica de cada aparato para lograr una desagregación de la energía sensada.

Las cargas eléctricas exhiben un patrón único de consumo energético llamado “firma de carga”, que hace posible a los algoritmos de desagregación el reconocimiento de la operación de un dispositivo particular desde la medición agregada carga. El reconocimiento de los aparatos tiene una dependencia alta de estas firmas de carga. Como propuso hace algunas décadas ya George Hart el consumo de los electrodomésticos puede ser categorizado basado en sus estados de operación, como se describe a continuación:

- Tipo I: Son aparatos con dos estados de operación (ON-OFF). Por ejemplo: lampara de mesa, tostadora, etc.
- Tipo II: Son dispositivos multi estado con un número finito de estados. Sus patrones de switcheo suelen ser repetibles, lo que facilita su desagregación. Dispositivos de esta categoría podrían ser lavadora, cocina de inducción, etc.
- Tipo III: Los aparatos de este tipo son conocidos como continuamente variable ya que su consumo de potencia tiene un número no definido de estados. Debido a esto es un reto para un sistema NILM desagregar su consumo de una medición de carga agregada. En esta categoría entrarían las luces dimerizables, los taladros de potencia, etc.
- Tipo IV: Pertenecen a esta categoría dispositivos que tienen un consumo constante por semanas o meses, suelen identificarse como aparatos de consumo permanente. En esta categoría estarían los teléfonos, decodificadores, detectores de humo cableados, etc.

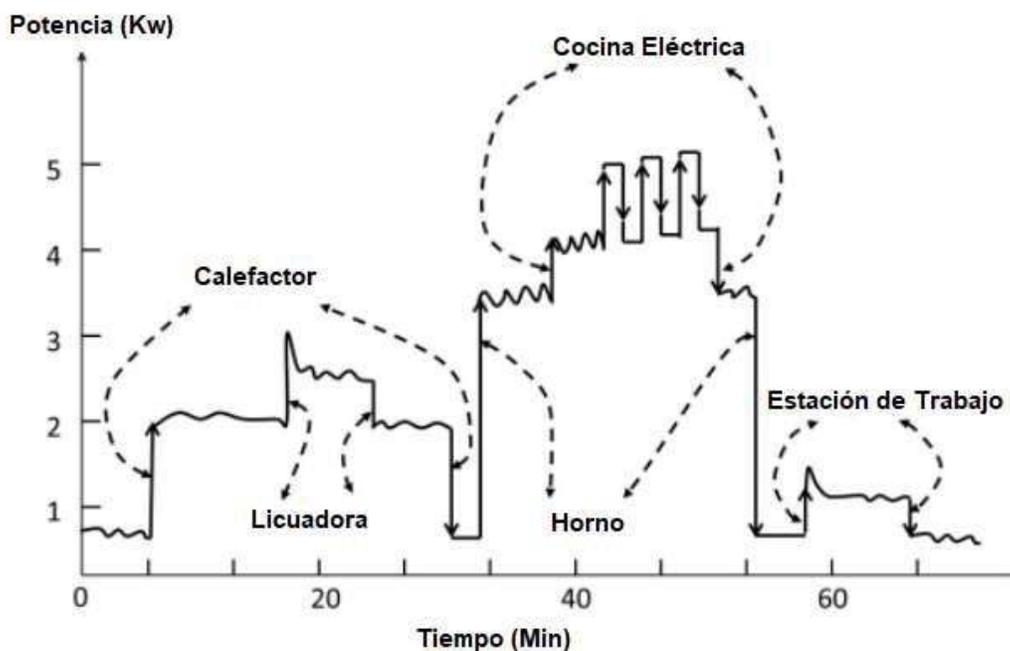


Figura 1.1 Primer concepto de NILM basado en un único punto de medida. [2]

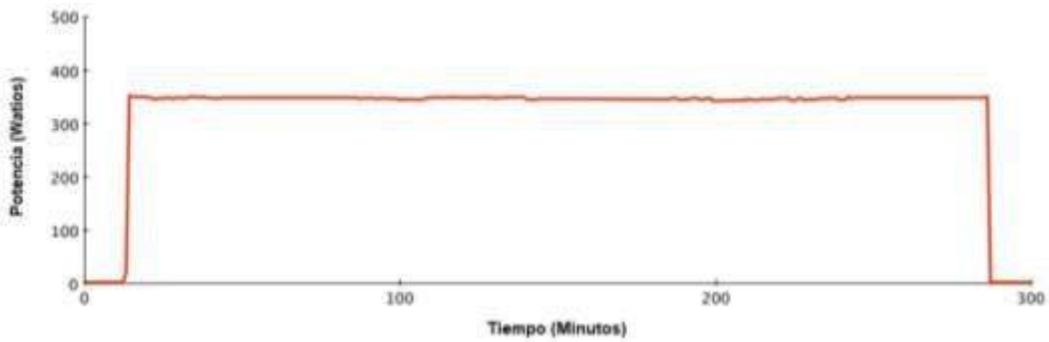


Figura 1.2 Dispositivo con Dos Estados de Operación (ON-OFF). [3]

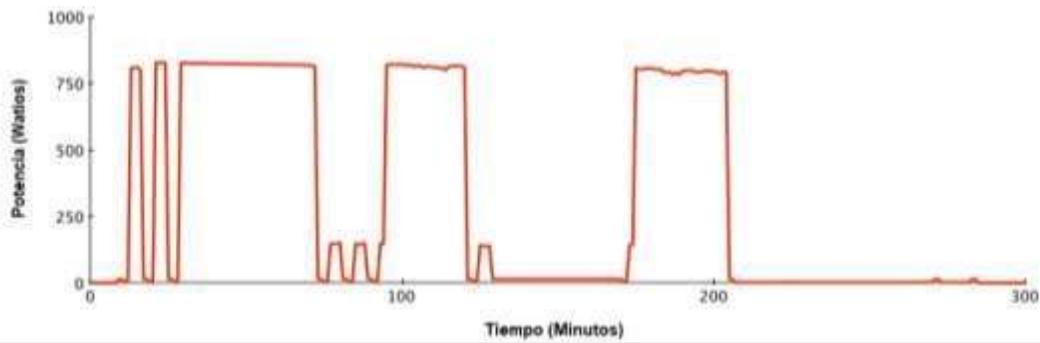


Figura 1.3 Dispositivo con Número Finito de Estados. [3]

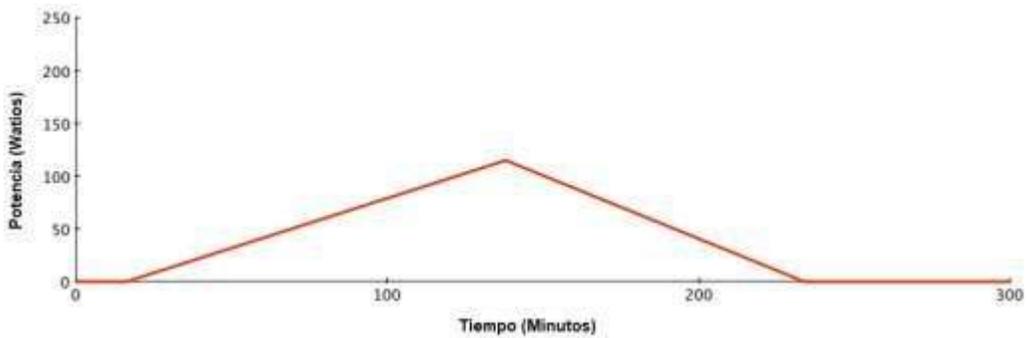


Figura 1.4 Dispositivo Continuamente Variable. [3]

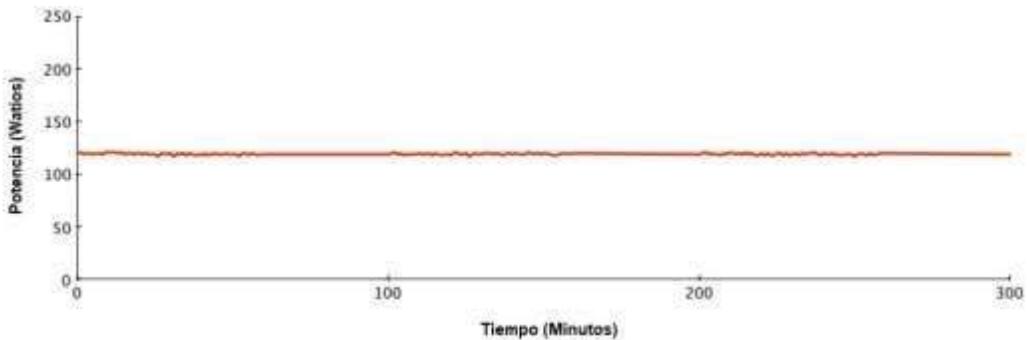


Figura 1.5 Dispositivo con Consumo Constante. [3]

Generalmente para hacer posible la desagregación de potencia o energía consumida se requiere de:

- Módulo de Adquisición de Datos
- Extracción de Características
- Clasificación de Carga.

1.3.1 MÓDULO DE ADQUISICIÓN DE DATOS

Para adquirir los datos agregados de energía se requiere de un módulo con una adecuada frecuencia de muestreo, que permita identificar los diferentes patrones, según los tipos de carga que se desee reconocer.

Existen una variedad de medidores de energía en el mercado, ya sean de baja o alta frecuencia de muestreo [2].

1.3.1.1 Medidores de Baja Frecuencia de Muestreo

La tasa de muestreo determina qué tipo de información podemos extraer de las señales eléctricas. Es así que si queremos extraer armónicos de orden superior debemos cumplir con el criterio de Nyquist-Shannon. Por ejemplo, si queremos obtener el cuarto armónico de una señal de 60 Hz necesitaremos muestrear a una frecuencia de 480 Hz.

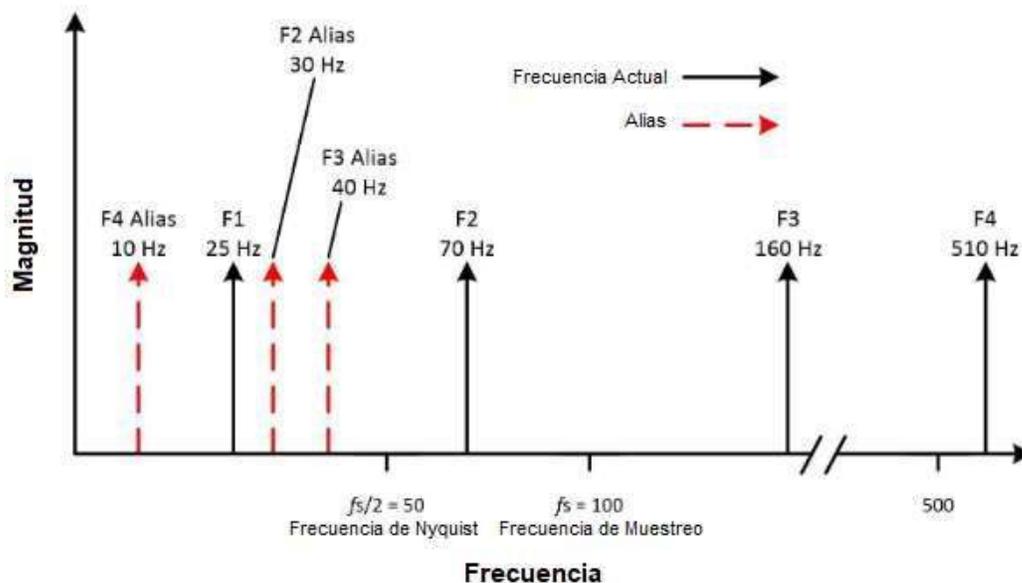


Figura 1.6 Ejemplo de Criterio Nyquist-Shannon. [7]

Ahora bien, para muestrear potencia activa, reactiva, corriente y voltaje RMS, se necesita una baja frecuencia de muestreo (120 Hz)

1.3.1.1 Medidores de Alta Frecuencia de Muestreo

Para capturar transitorios o ruido eléctrico generado por las señales eléctricas se necesita muestrear las formas de onda a una frecuencia mucho más alta, de alrededor de 10 a 100 MHz [2]. Dispositivos que permitan este tipo de muestreo suelen ser muy costosos debido a su hardware sofisticado. Razón por la cual no son usados en soluciones comerciales domiciliarias.

1.3.2 EXTRACCIÓN DE CARACTERÍSTICAS

Una vez detectado el evento con el módulo de adquisición de datos, se procede a comparar varias características extraídas de la señal de potencia monitoreada.

Estas características podrían ser diferentes mediciones, ya sean inherentes al estado estable (corriente, potencia, etc.) o al transitorio de la muestra. Estos datos son etiquetados para usarlos en el entrenamiento del sistema NILM. Es importante obtener el correcto conjunto de características a etiquetar para permitir la correcta clasificación del dispositivo que ha disparado el evento.

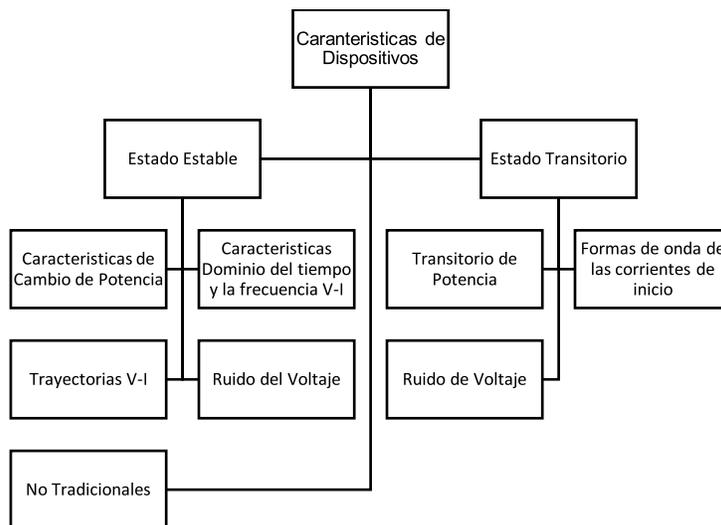


Figura 1.7 Taxonomía de las Características de los Dispositivos.

1.3.2.1 Firma del Estado Estable

Se define estado estable en el ámbito eléctrico, como una señal que no presenta variaciones en el tiempo entre dos muestras de una secuencia, más allá de una tolerancia dada. Usando únicamente la potencia activa en estado estable se ha presentado muchos errores de clasificación, ya que una gran cantidad de dispositivos tienen unas firmas en estado estable similares. Para mejorar la distinción de dispositivos investigadores han basado su identificación en la razón entre las áreas rectangulares delimitadas por los distintos valores de estado. Las firmas en estado estable de dispositivos de bajo consumo

de potencia (teléfonos, detectores de humo, etc.) muchas veces no son clasificados ya que no cambian su potencia en estado estable o sus cambios se asemejan a ruido eléctrico [3].

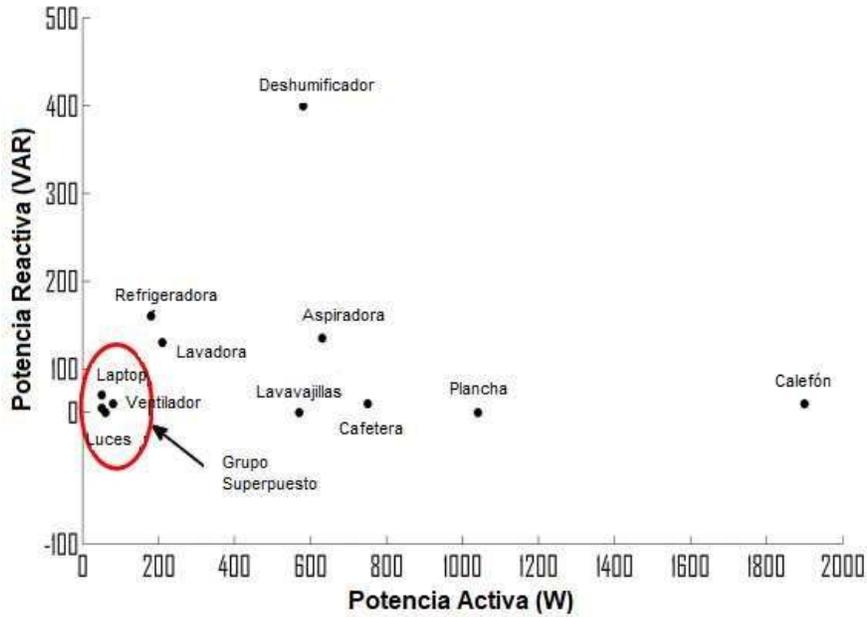


Figura 1.8 Distribución de cargas en el plano P-Q. [2]

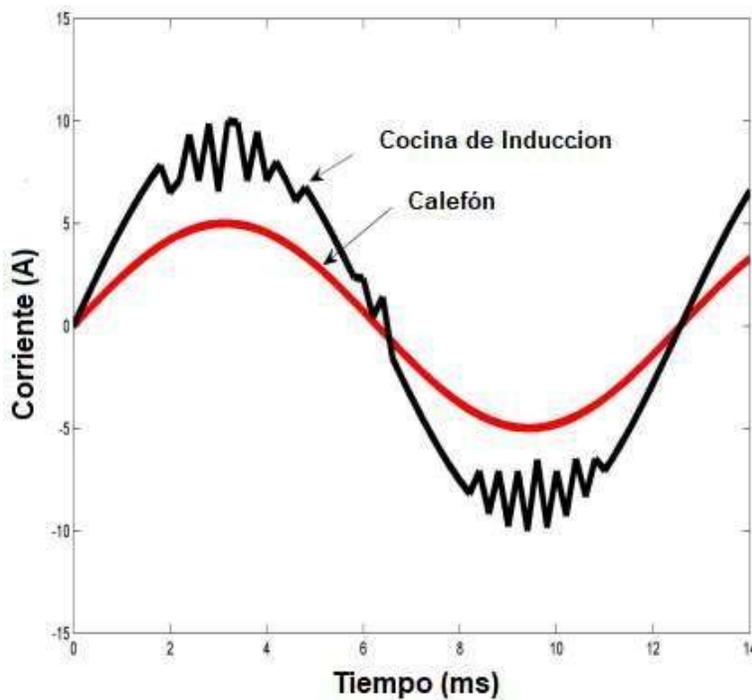


Figura 1.9 Grafica de Corriente de Carga Lineal vs No Lineal. [2]

Existen varios métodos para extraer las características necesarias para el desarrollo de sistemas de monitoreo de carga no intrusiva, como se muestra en la Tabla 1.1.

Tabla 1.1 Resumen de los Métodos en Estado Estable.

Métodos en Estado Estable	Características	Ventajas	Deficiencias
Cambios de Potencia	Variación en estado estable de la potencia activa y reactiva	Dispositivos de alta potencia pueden ser fácilmente identificados. Se requiere una frecuencia de muestreo baja	Dispositivos de baja potencia se superponen en el plano P-Q. Pobre desempeño en reconocer cargas del Tipo II, III y IV.
Dominio del Tiempo y la Frecuencia de las Formas de Onda V-I	Armónicos de orden superior en estado estable, Irms, Imedia, Ipico, Vrms, Factor de Potencia	Los dispositivos pueden fácilmente ser categorizados en cargas resistivas, inductivas y electrónicas	Se requiere alta frecuencia de muestreo, poca precisión para cargas del tipo III, se superponen características para cargas del tipo I y II, no se puede distinguir eventos de activación q se superponen
Trayectorias V-I	Formas características de trayectoria V-I: asimetría, dirección del bucle, área, curvatura de la línea media, auto intersección, pendiente media, área de segmentos y pico del segmento medio.	Se puede realizar una taxonomía detallada de los dispositivos gracias a las curvas V-I distintivas.	Alta sensibilidad a la operación de cargas múltiples, computacionalmente demandante, cargas pequeñas no tienen patrones de trayectoria.
Ruido de Voltaje	Firmas de las Interferencias Electromagnéticas EMI	Aparatos basados en motores pueden ser fácilmente distinguidos pues generan un ruido de voltaje	Sensibles a la arquitectura del cableado, firmas de las interferencias

		sincrónico. Se puede detectar eventos de activación simultáneos. Dispositivos equipados con fuentes conmutadas pueden ser reconocidos con alta precisión.	electromagnéticas se superponen. No todos los dispositivos son equipados con fuentes conmutadas.
--	--	---	--

1.3.2.2 Firma del Estado Transitorio

A diferencia del estado estable que no tiene variación entre dos muestras de una secuencia, el transitorio sí. Dado que cada dispositivo está hecho con una diferente configuración de elementos (resistencias, capacitores, etc.), estos causan cambios en la señal de potencia y en la firma transitoria.

Tabla 1.2 Resumen de los Métodos en Estado Transitorio.

Métodos Transitorios	Características	Ventajas	Deficiencias
Potencia Transitoria	Transitorio de Potencia repetible. Envolturas Espectrales	Dispositivos con la misma forma de potencia pueden ser fácilmente identificados. Se reconoce cargas del tipo I, II, III.	Monitoreo continuo, alta frecuencia de muestreo, no óptimo para cargas del tipo IV.
Transitorio en la Corriente Inicial	Picos de Corriente, tamaño, duración, formas del transitorio en el switcheo, Tiempo de respuesta del transitorio	Trabaja bien para los tipos I y II. Se distingue el comportamiento transitorio en la operación de múltiples cargas.	Pobre detección en secuencias de activación y desactivación simultánea. Incapaz de caracterizar cargas del tipo III y IV. Sensible a la estructura del cableado. Dispositivos específicos.
Muestras de ruido de voltaje en alta frecuencia	Transformada rápida de Fourier del ruido	Dispositivos multi-estado. Aparatos electrónicos con fuentes conmutadas	Dispositivos específicos, computacionalmente demandante. Manejo de datos muy complejo

1.3.2.3 Características No Tradicionales

Dejando de lado los tradicionales análisis en estado estable y transitorios, recientemente se ha visto un alto interés en métodos de extraer características para adquirir características no tradicionales de los dispositivos. Recientemente investigadores han planteado la posibilidad de representar el consumo de potencia de los dispositivos domiciliarios como una combinación de dos unidades, triangulares y rectangulares, junto con pequeñas fluctuaciones [4]. Se ha argumentado que este enfoque permitiría reducir la problemática de características de dispositivos superpuestas. Las unidades rectangulares pueden ser expresadas mediante el tiempo de inicio, valor pico, tiempo pico, tiempo estable, potencia estable, las unidades triangulares pueden ser expresadas mediante valor pico, tiempo de inicio, valor pico, tiempo final. El proceso de identificación de carga combina características fundamentales con otros estilos de trabajo que ofrecen una precisión del 80 %. La mayor ventaja de este método es que no requiere ni entrenamiento ni supervisión. Algunos investigadores proponen la combinación de algunas características para desagregar la carga, como: armónicos, potencia activa, potencia reactiva, admitancia, n-ésimos valores de las formas de onda de corriente, etc. Otras características no tradicionales incluyen, la hora del día, distribución de la duración del encendido y apagado, frecuencia del uso del dispositivo, así como la correlación entre el uso de los diferentes dispositivos, lo que ha ayudado a mejorar la desagregación de los dispositivos domiciliarios.

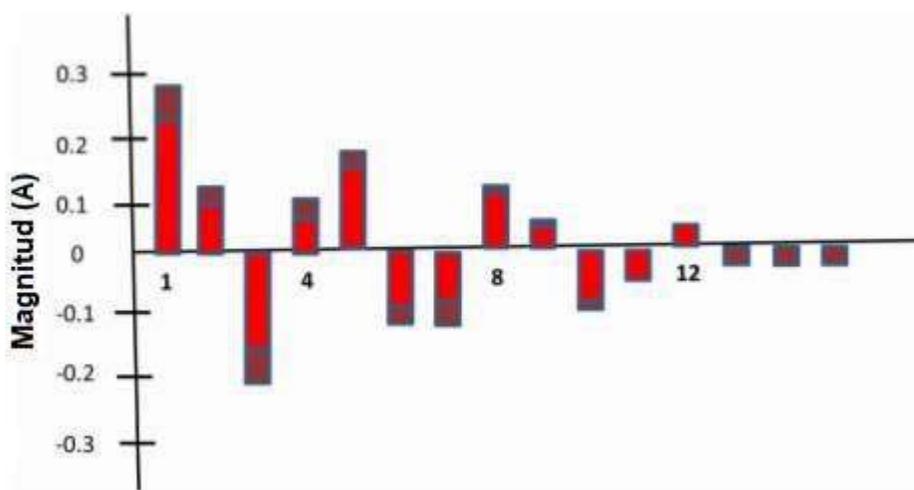


Figura 1.10 Monitoreo de Harmónicos donde las porciones negras indican las fluctuaciones. [2]

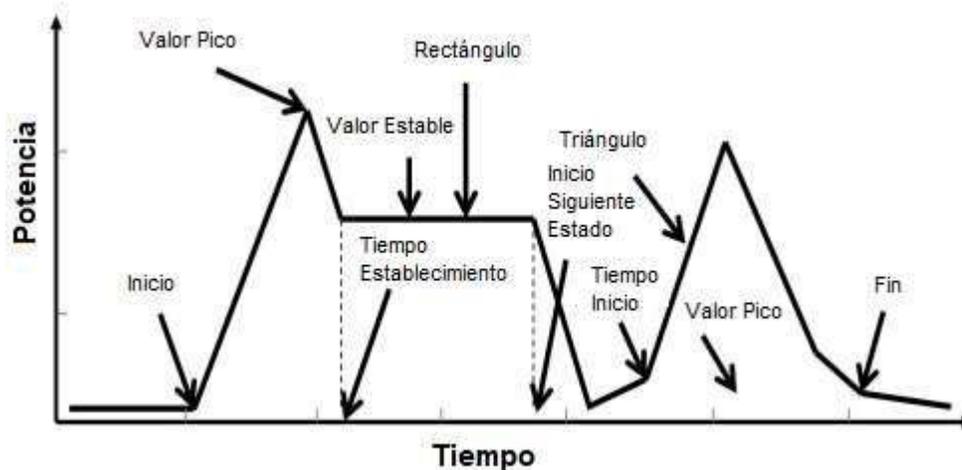


Figura 1.11 Diagrama Esquemático de las Dos Unidades Gráficas. [2]

1.3.2.4 Clasificación de la Carga

Finalmente, un sistema NILM se encarga de clasificar que dispositivo disparo el evento a analizar. Para aquello se utiliza las características previamente extraídas en las tareas anteriores, así como los datos etiquetados. Normalmente los investigadores han utilizado algoritmos de machine learning para realizar estas tareas de clasificación. Siendo los algoritmos que tienen entrenamiento supervisado los usados de forma estándar. Los algoritmos que tienen un aprendizaje supervisado más comúnmente usados son:

- Redes Neuronales Artificiales (Artificial Neural Network)
- Máquina de Vectores de Soporte (Support Vector Machine)
- Vecino más Cercano (Nearest Neighbor)

También se ha usado algoritmos con aprendizaje no supervisado, aunque no de manera estándar. En recientes publicaciones se han centrado en diferentes formas de:

- Factorial Oculto Modelos de Markov (Hidden Markov Models)

En esta sección trataremos los algoritmos de clasificación más usados tanto de manera estándar como no estándar.

1.3.2.4.1 Redes Neuronales Artificiales (Artificial Neural Network)

El cerebro humano corresponde al símil de un sistema altamente complejo no lineal y paralelo. En términos simples, puede realizar múltiples operaciones de manera simultánea a diferencia de los computadores que son de tipo secuencial es decir

realizan una sola operación a la vez. En este sentido una red neuronal se puede considerar como un procesador de información, de distribución altamente paralela, constituido por gran cantidad de unidades sencillas de procesamiento llamadas neuronas.

Con el fin de modelar un símil artificial de una red neuronal biológica, se pretende modelar no su comportamiento fisiológico, sino más bien únicamente sus características más relevantes, que interaccionan con toda la red.

En una neurona artificial estándar y_j , las n neuronas de entrada x_i envían señales representadas por valores numéricos. Los pesos sinápticos W_{ji} , multiplican su señal de entrada y definen la importancia relativa de cada neurona de entrada. El conjunto de los elementos antes mencionados se ha llamado perceptrón simple.

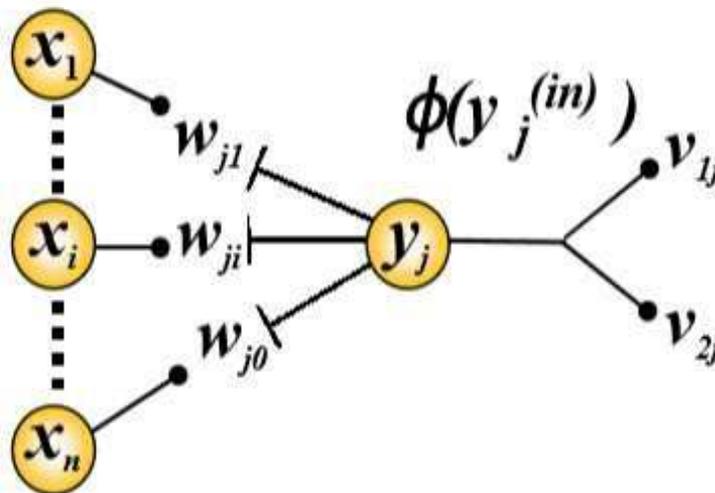


Figura 1.12 Diagrama Esquemático de un Perceptrón Simple. [5]

Entonces tenemos que la entrada total de la neurona y_j es:

$$y_j^{input} = \sum_{i=1}^n W_{ji} X_i \quad (1.2)$$

La neurona se activa si la entrada supera cierto umbral; para modelar esto se aplica una función de activación, que puede ser una función escalón, sigmoide, tangencial hiperbólica, etc. Entonces tenemos que la señal de salida o salida de la neurona y_j es:

$$y_j^{out} = f(y_j^{input}) \quad (1.3)$$

A continuación, se presentan algunas funciones de activación no lineales típicas.

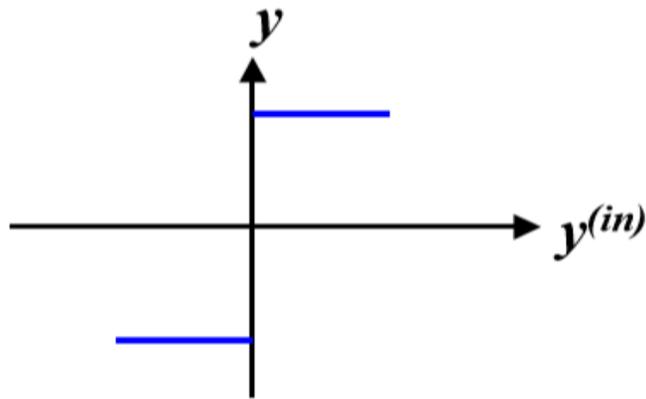


Figura 1.13 Función de activación tipo paso. [5]

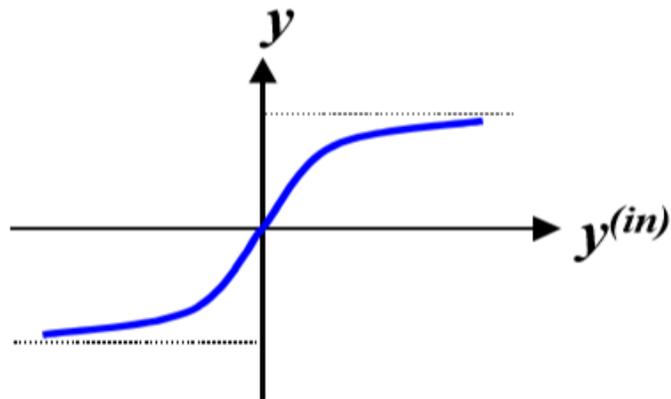


Figura 1.14 Función de activación tipo sigmoide. [5]

Evidentemente estas funciones de activación transmiten la idea de dispararse sobre un umbral. Pues bien, algunas veces es deseable modificar este umbral de activación haciendo que sea más difícil o menos difícil su activación. Para que el nivel de programación no se complique se introduce una entrada llamada de inclinación, la misma que tiene un valor fijo $x_i = 1$ y un peso sináptico w_{j0}

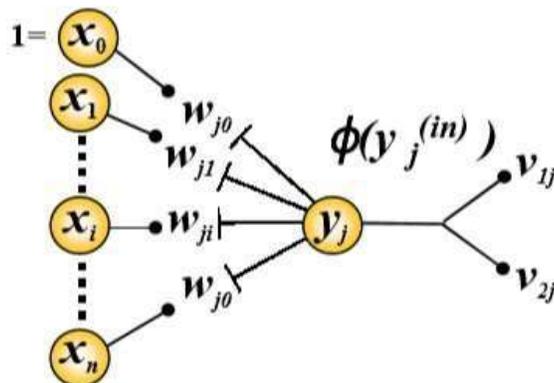


Figura 1.15 Esquema de una Perceptrón Simple con Entrada de Inclinación. [5]

Tenemos que la entrada total de la neurona y_j es:

$$y_j^{input} = \sum_{i=0}^n W_{ji}X_i \text{ donde } x_0 = 1 \quad (1.4)$$

El perceptrón simple presenta grandes limitaciones, ya que solo es capaz de representar funciones linealmente separables. Una manera de solventar estas limitaciones del perceptrón simple es por medio de la inclusión de capas ocultas, obteniendo de esta forma una red neuronal que se denomina perceptrón multicapa [5].

Las regiones de decisión de una red neuronal dependen de la arquitectura de esta. Así por ejemplo la región de decisión del perceptrón simple es una recta, mientras que perceptrón multicapa con una única capa de neuronas ocultas discrimina una región convexa. Por otro lado, un perceptrón multicapa con dos capas ocultas puede discriminar regiones de forma arbitraria.

EL Perceptrón Multicapa suele programarse por medio de una retro propagación de errores conocida normalmente como BackPropagation de ahí que ese tipo de arquitectura se conozca como red de retro propagación.

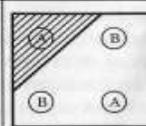
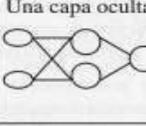
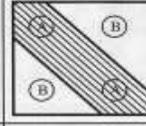
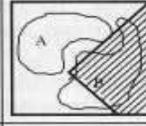
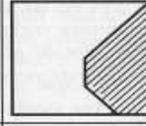
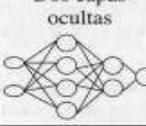
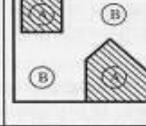
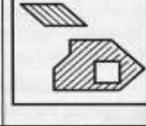
Arquitectura	Región de decisión	Ejemplo 1: XOR	Ejemplo 2: clasificación	Regiones más generales
 Sin capa oculta	Hiperplano (dos regiones)			
 Una capa oculta	Regiones polinomiales convexas			
 Dos capas ocultas	Regiones arbitrarias			

Figura 1.16 Regiones de Decisión para distintas Arquitecturas de una Red Neuronal. [8]

La arquitectura de Perceptrón Multicapa goza de gran popularidad, ya que con una única capa oculta puede aproximar cualquier función continua en un intervalo hasta el nivel deseado, aunque no se encuentra documentado el número de nodos en la capa oculta necesarios para dicha aproximación.

Como ya se mencionó, el perceptrón multicapa se entrena mediante el ajuste de los pesos usando retro propagación Sin embargo el esfuerzo computacional para encontrar la combinación de pesos incrementa sustancialmente cuando más parámetros y más topologías complicadas son consideradas. Para solventar esta problemática se ha desarrollado el algoritmo de retro propagación (BackPropagation Algorithm). Este algoritmo

busca el mínimo de la función de error en el espacio de pesos usando el método de optimización llamado descenso de gradiente [6]. La combinación de pesos que minimiza la función de error es considerada para ser una solución del problema de aprendizaje. Dado que este método requiere el computo del gradiente de la función de error en cada paso de iteración, se debe garantizar la continuidad y diferenciabilidad de la función de error. Obviamente no se puede usar la función paso como función de activación, muy usada en el caso de perceptrón simple, ya que es discontinua y su función de error también.

La función de activación más usada en las redes retro propagadas es la sigmoide, definida por la expresión:

$$f(x) = \frac{1}{1+e^{-cx}} \quad (1.5)$$

La constante c puede ser seleccionada de forma arbitraria, y su recíproco es llamado el parámetro de temperatura en las redes neurales estocásticas. La forma de la función de activación cambia a medida que se cambia el valor de c como se puede ver a continuación.

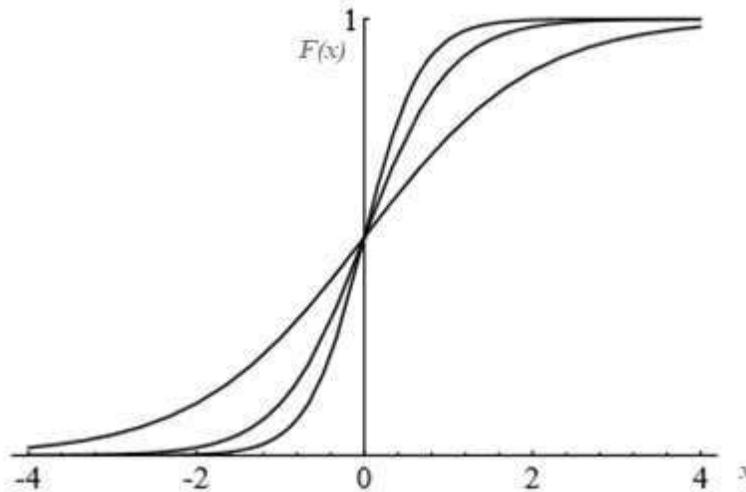


Figura 1.17 Sigmoides para Distintos Valores de c . [6]

La derivada de la función sigmoide respecto a x , donde $c = 1$ es:

$$\frac{d}{dx} f(x) = \frac{e^{-x}}{(1+e^{-x})^2} = f(x)(1 - f(x)) \quad (1.6)$$

Muchas veces, en el caso del perceptrón, una función de activación simétrica ofrece algunas ventajas para el aprendizaje. Por eso como alternativa a la sigmoide tenemos a la sigmoide simétrica, definida como:

$$F(x) = \frac{1-e^{-x}}{1+e^{-x}} = 2f(x) - 1 \quad (1.7)$$

Dado que necesitamos seguir la dirección del gradiente para llegar al mínimo, es importante que no existan regiones en las que la función de error sea completamente plana. De hecho, la función sigmoide siempre tiene una derivada positiva, por lo que la función de error presenta una pendiente que proporciona una dirección de descenso mayor o menor.

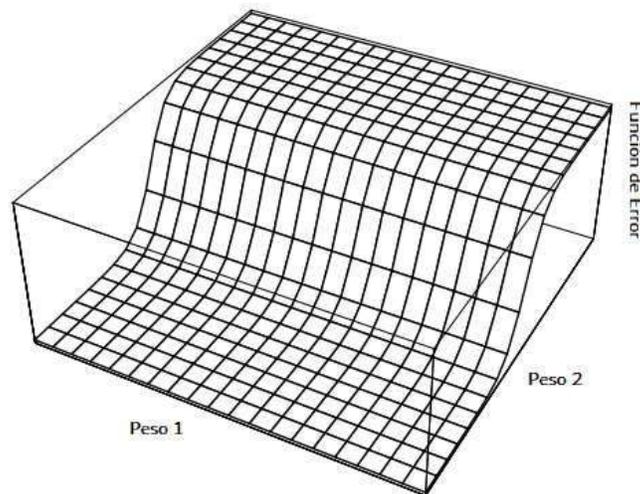


Figura 1.18 Gráfico de una Parte de una Función de Error. [6]

No todo podía ser positivo con la función de activación sigmoide, pues un punto negativo reside en que la función de error resultante tendrá mínimos locales y un mínimo global. En el siguiente gráfico se observa un mínimo local que tiene un nivel de error mucho más alto que en otras regiones. Para computar esta función de error se ha utilizado una unidad única con dos pesos y cuatro patrones de entrada-salida en el set de entrenamiento.

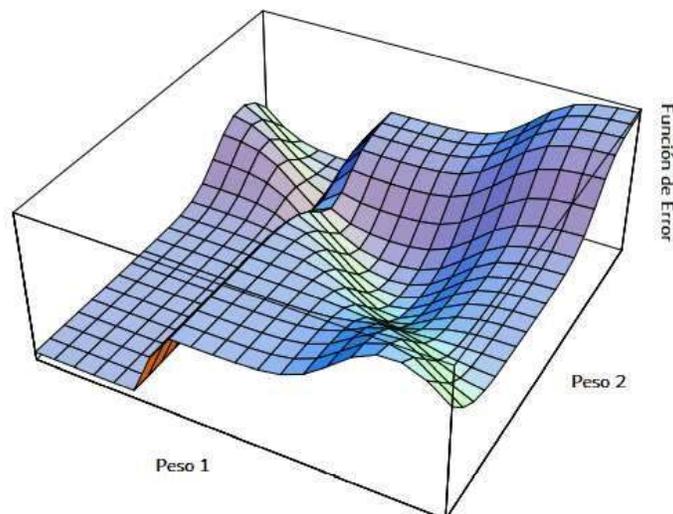


Figura 1.19 Mínimo Local de una Función de Error. [6]

Existe un valle en esta función de error y si el método de optimización de descenso de gradiente empezara allí, nunca se llegaría al mínimo global. Muchas veces los mínimos locales aparecen ya que los objetivos de entrenamiento son 0 o 1.

Una vez analizada la función de activación más utilizada en redes neuronales retro propagadas y sus ventajas, así como su deficiencia, sería conveniente centrarnos en los pasos que componen un algoritmo de retro propagación (Backpropagation Algorithm). Los mismos que, teniendo en cuenta que los pesos de la red son inicializados con valores numéricos aleatorios, son:

- Cálculo de la red prealimentada (feed-forward)
- Retro propagación a la capa de salida
- Retro propagación a la capa oculta
- Actualización de los pesos

El algoritmo se detiene cuando la función de error se ha hecho lo suficiente mente pequeña.

2. METODOLOGÍA

En este capítulo se tratará todos los detalles de nuestra implementación, cuyos tópicos son los siguientes:

- Medidor de Parámetros Eléctricos
- Selección del Ordenador que ejecute una Red Neuronal
- Software de Clasificación
- Entrenamiento de la Red Neuronal Artificial
- Aplicación Android

A continuación, se expande cada una de las partes constitutivas de nuestro proyecto.

2.1 MEDIDOR DE PARÁMETROS ELÉCTRICOS

Uno de los componentes medulares de este proyecto, es el medidor de parámetros eléctricos del sistema domiciliario a tratar. El mismo que debe cumplir con la exigencia de ser de fácil instalación, así como altamente fiable. En los siguientes subtemas se tratará con mayor profundidad el diseño de dicho medidor.

2.1.1 SELECCIÓN DEL CHIP MEDIDOR DE PARÁMETROS ELÉCTRIOS

Dado que necesitamos obtener los parámetros eléctricos de una red monofásica, y enviar estos datos hacia la raspberry pi que contendrá nuestra red neuronal artificial. Podríamos pensar en armar una circuitería analógica que tome muestras de voltaje y corriente, y a partir de estos datos haga un cálculo en el dominio discreto de los distintos parámetros medibles de una red. Pero en la actualidad existen ya un sin número de circuitos integrados que realizan todas estas tareas de manera integrada. A continuación, listaremos algunos junto con sus características.

Tabla 2.1 Comparación Circuitos Integrados Medidores de Energía.

PARÁMETRO	ADE7757A	ADE7755	ADE7753	ADE7759A
Energía Activa	SI	SI	SI	SI
Energía Reactiva	NO	NO	SI	NO
Energía Aparente	NO	NO	SI	NO
Voltaje RMS	NO	NO	SI	SI
Corriente RMS	NO	NO	SI	SI
Calibración Digital	NO	SI	SI	SI
Salida de Pulsos	SI	SI	SI	SI
Puerto Serial	NO	SI	SI	SI
Interrupción	NO	SI	SI	SI

Salida de Cruce por Cero	NO	SI	SI	NO
Supervisión de Fuente de Poder	NO	SI	SI	SI
Oscilador Integrado	SI	NO	NO	NO
Fabricante	ANALOG DEVICE	ANALOG DEVICCE	ANALOG DEVICE	ANALOG DEVICE
PRECIO USA	\$2,93	\$3,51	\$4,19	\$4,79

Por las características que ofrece el circuito integrado ADE7753 será el escogido para ser parte de nuestro proyecto.

2.1.2 DISEÑO MEDIDOR PARÁMETROS ADE7753

En el diseño del medidor de energía usando el ADE7753, lo fundamental es el acondicionamiento de voltaje como de corriente. Ya que las entradas de los canales 1 y 2 tiene un voltaje máximo de entrada. En la Figura 2.1 se presenta el circuito sugerido por el fabricante.

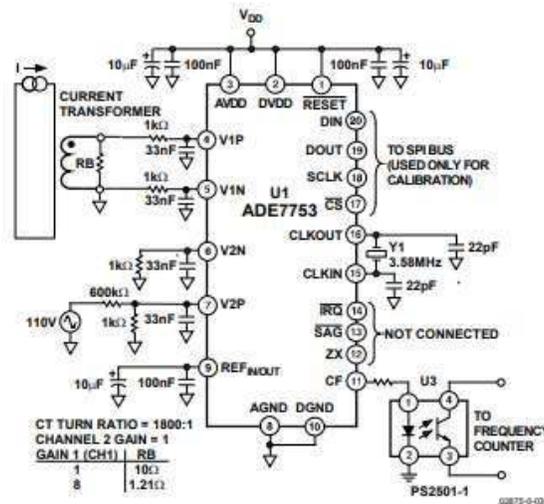


Figura 2.1 Circuito de Prueba Sugerido por el Fabricante sin Integrador. [9]

2.1.2.1 ACONDICIONAMIENTO DE CORRIENTE

Como se detalló anteriormente, los canales ADC del ADE7753 tiene un voltaje máximo de entrada. Este voltaje limite es $\pm 0.5 V$, por ello necesitamos acondicionar nuestra entrada de corriente a estos niveles.

En nuestro caso hemos escogido el sensor de corriente SCT-013 que nos da una salida de voltaje de 1V AC para una corriente de 30 A. Pero en lugar de utilizar un divisor de tensión

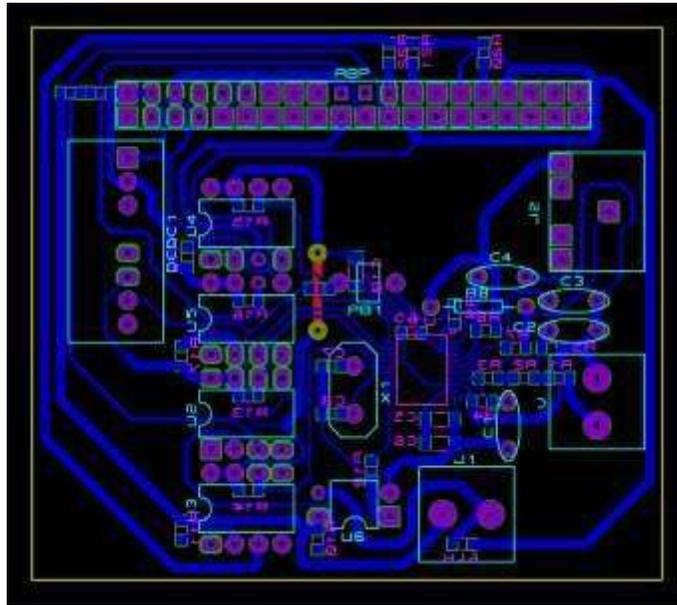


Figura 2.2 Diseño PCB del Circuito Medidor de Energía.

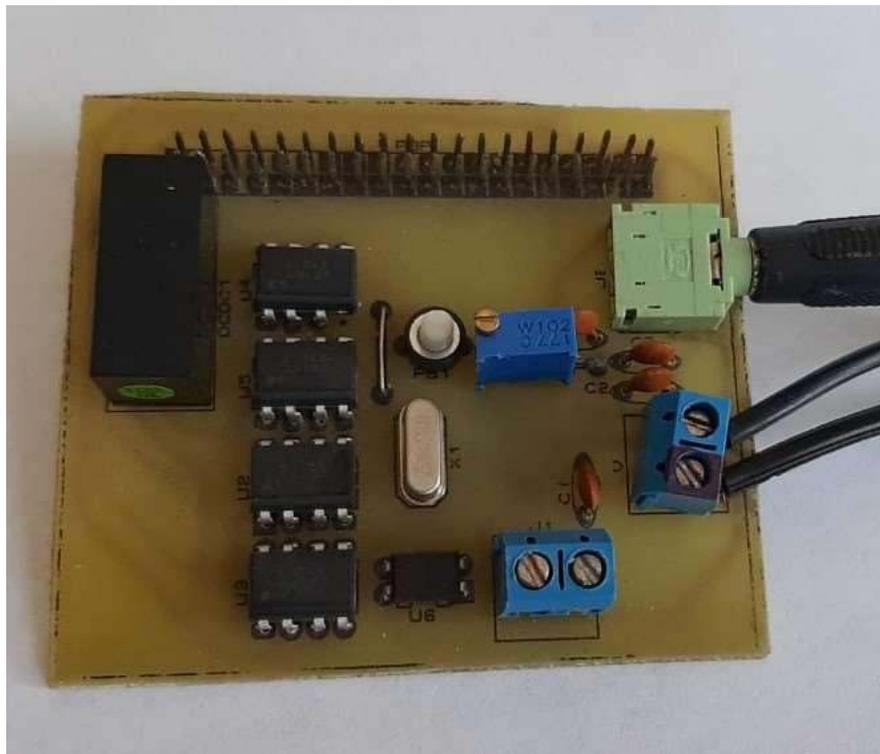


Figura 2.5 Imagen Superior del Medidor de Energía Implementado



Figura 2.6 Imagen Inferior del Medidor de Energía Implementado

2.1.3 CALIBRACIÓN DEL MEDIDOR DE PARÁMETROS ELÉCTRICOS

Cuando se desea calibrar cualquier dispositivo de medición, se requiere de un equipo patrón o de referencia. En nuestro caso, se adquirió un equipo medidor de parámetros eléctricos para este fin, este equipo es de la compañía SELECT; y nombre referencia es MFM376. Aunque el dispositivo toma mediciones trifásicas, también se puede programar para que tome mediciones únicamente monofásicas. Este medidor nos muestra los siguientes parámetros:

- Voltaje RMS
- Corriente RMS
- Potencia Activa
- Potencia Reactiva
- Potencia Aparente
- Ángulo de desfase entre voltaje y corriente
- Distorsión armónica de voltaje y corriente
- Factor de potencia

Para llevar a cabo la calibración, se ha tomado al mismo tiempo lecturas de los parámetros de interés en el medidor de referencia y en nuestro medidor implementado. Luego de lo cual se utilizó el programa Excel para graficar y obtener la tendencia lineal de dichos datos.

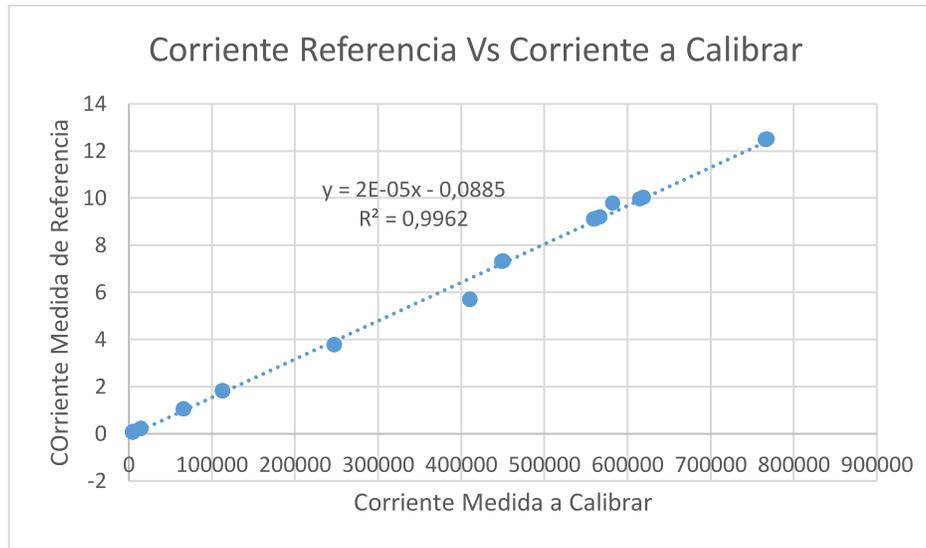


Figura 2.3 Tendencia lineal de la lectura de corriente de referencia y a calibrar

El mismo procedimiento se ha realizado para los parámetros: voltaje, potencia activa y potencia aparente, datos que necesitamos para poder desagregar los dispositivos en nuestro proyecto. Luego del proceso de calibración se ha tenido los siguientes resultados:

Tabla 2.3 Error en la Medición de Voltaje.

Parámetro	Voltaje (V)			
Referencia				
Medidor Patrón	121.30	117.60	118.90	114.30
Medidor implementado	122.36	117.80	119.50	113.89
Porcentaje de Error	0.87	0.17	0.50	0.36

Tabla 2.4 Error en la Medición de Corriente.

Parámetro	Corriente (A)			
Referencia				
Medidor Patrón	0.30	1.03	7.35	12.58
Medidor implementado	0.31	1.07	7.36	12.60
Porcentaje de Error	1.90	3.80	0.16	0.16

Tabla 2.5 Error en la Medición de Potencia Activa.

Parámetro Referencia	Potencia (KW)			
	Medidor Patrón	0.037	0.147	253.000
Medidor implementado	0.038	0.153	255.820	891.54
Porcentaje de Error	2.600	3.900	1.100	0.95

Tabla 2.6 Error en la Medición de Potencia Aparente.

Parámetro Referencia	Potencia (KVA)			
	Medidor Patrón	0.038	0.162	0.255
Medidor implementado	0.039	0.166	0.260	0.909
Porcentaje de Error	2.560	2.410	1.920	0.770

2.2 SELECCIÓN DEL ORDENADOR QUE EJECUTE UNA RED NEURONAL

En la selección del ordenador necesario para nuestra implementación tenemos que tener en cuenta una serie de factores. Dentro de estos factores el principal es la relación costo-características. De ahí que muchas de las implementaciones básicas, se realicen con ordenadores de placa reducida o comúnmente conocidos como mini computadoras. A continuación, se listarán algunos tipos de mini ordenadores con sus respectivas características.

Tabla 2.7 Comparativa de algunos ordenadores de placa reducida.

Dispositivo	Procesador	Ram	Memoria Interna	Conectividad	*Precio
Jaguar One	Intel Atom Z3735G	1 GB DDR3	16 GB	3 USB 2.0, HDMI 1.4 y Ethernet	\$79

Orange PI	ARM A7 4x1.2 Ghz	512 MB	Tarjeta de memoria	1 USB 2.0, HDMI y Ethernet	\$10
Odroid-C2	ARM A53 4x2 Ghz	2 GB DDR3	Tarjeta de memoria interna	4 USB 2.0, HDMI 2.0 y Ethernet	\$40
pcDuino4	ARM A7 4 núcleos (Allwinner H3)	1 GB DDR3	8 GB	2 USB 2.0, HDMI 2.0 y Ethernet	\$49
Raspberry Pi 3 B+	ARM Cortex-A53	1GB	Tarjeta de memoria	4 x USB 2.0, Wifi, Bluetooth y Ethernet	\$35

*Los precios de la tabla anterior son de los ordenadores en Estados Unidos.

En la tabla anterior solo se han listado unos pocos mini ordenadores de los varios que existen en el mercado internacional. Así pues, podemos seleccionar la Raspberry Pi 3 B+ por su conectividad, precio y facilidad de obtención en el país.

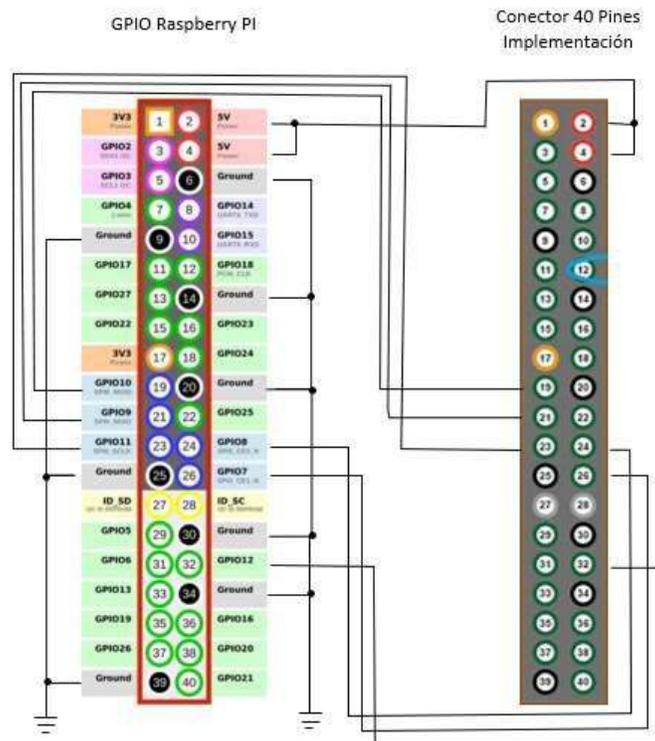


Figura 2.4 Diagrama Esquemático Conexión Raspberry Pi-Medidor de Energía Implementado

2.3 SOFTWARE DE CLASIFICACIÓN

Como se ha listado en el Capítulo 1, existen algunos métodos de clasificación. En nuestro proyecto se ha decidido usar el algoritmo de redes neuronales artificiales, ya que existen múltiples librerías que permiten su implementación. Además, su entrenamiento es más fácil de realizar, a pesar de que lleva mucho tiempo y recursos económicos si se desea generalizar.

Entre la gran cantidad de lenguajes de programación, se ha decidido usar Python 3.7, por ser fácil de abstraer su utilización. A pesar de ello es una herramienta muy útil, ya que tiene una gran cantidad de librerías de código abierto y gratuitas en campos tan diversos como la estadística, aprendizaje automático, minería de datos, etc.

Actualmente existen un sin número de IDE's (Integreted Develoment Environment) que soportan Python 3.7, pero se ha utilizado Spyder para este proyecto específico.

2.3.1 RED NEURONAL ARTIFICIAL USANDO PYTHON

Para implementar nuestra red neuronal se ha utilizado la librería scikit-learn 0.21.3. Esta permite realizar las siguientes tareas [10]:

- Clasificación
- Regresión
- Agrupamiento
- Reducción de la Dimensionalidad
- Selección de Modelo
- Preprocesamiento

En nuestro interés esta realizar la clasificación de dispositivos así que usaremos las herramientas asociadas a dicha tarea. Una de estas es MLPClassifier, la cual nos permite implementar un perceptrón multicapa que es entrenado mediante retro propagación. MLPClassifier consta de los siguientes parámetros:

- `hidden_layer_size`: dato tipo tupla que nos indica el número neuronas de cada capa oculta de nuestra red. (default=100)
- `activation`: indica la función de activación de la capa oculta. {'identity', 'logistic', 'tanh', 'relu'}, default 'relu'
 - `identity`: retorna el mismo valor de ingreso.
 - `logistic`: función logística sigmoide
 - `tanh`: función tangencial hiperbólica
 - `relu`: función unidad rectificadora lineal
- `solver`: método para la optimización de los pesos (default='adam')

- lbfgs: es un optimizador de la familia de los métodos cuasi Newtonianos.
- sgd: descenso por el gradiente estocastico
- adam: hace referencia a un método basado en el descenso por el gradiente propuesto por Kingma, Diederick y Jimmy Ba.
- alpha: es un término para regularización (default=0.0001)
- batch_size: tamaño de los mini lotes para optimizaciones estocásticas (default='auto').
- learning_rate: tasa de aprendizaje programado para actualizaciones de peso. Solo se usa cuando solver='sgd' (default=constant).
 - constant. tasa de aprendizaje constante
 - invscaling: decrece gradualmente la tasa de aprendizaje en cada paso de tiempo.
 - adaptative: mantiene la tasa de aprendizaje constante mientras las pérdidas de entrenamiento permanezcan decreciendo.
- learning_rate_init: tasa de aprendizaje inicial usada (default=0.001)
- max_iter: máximo número de iteraciones hasta converger. (default=200)
- tol: tolerancia de optimización (default=1e-4)
- verbose: si es que se deben imprimir informes del progreso (default=false).
- warm-start: Cuando se establece en Verdadero, reutilice la solución de la llamada anterior para que se ajuste como inicialización; de lo contrario, simplemente borre la solución anterior (default=false).
- momentum: momentum para la actualización del descenso por el gradiente. Debe estar entre 0 y 1 (default=0.9).
- nesterovs_momentum: si es que se usa el momentum de Nesterov (default=true).
- early_stopping: define si se usa un paro temprano para terminar el entrenamiento cuando el valor de validación no está mejorando en n_iter_no_change épocas (default=False).
- validation_fraction: la proporción de datos de entrenamiento usados como conjunto de validación para un early stopping (default=0.1)
- n_iter_no_change: número máximo de épocas para no cumplir con las mejoras de tol (default=10).

Puesto que la mayor parte de problemas se ha resuelto usando una única capa oculta, nuestro diseño contara con una única capa oculta. Las entradas de nuestra red serán los parámetros medidos con el circuito integrado ADE7753 que son: Potencia Activa Instantánea, Potencia Aparente Instantánea, Voltaje RMS y Corriente RMS. En el caso de

las salidas, serán las clases formadas por la combinación de los cinco dispositivos que nos hemos propuesto reconocer.

Tabla 2.8 Número de clases en las que clasificar nuestra red.

Dispositivo 1	Dispositivo 2	Dispositivo 3	Dispositivo 4	Dispositivo 5	Clase
0	0	0	0	0	0
0	0	0	0	1	1
0	0	0	1	0	2
0	0	0	1	1	3
0	0	1	0	0	4
0	0	1	0	1	5
0	0	1	1	0	6
0	0	1	1	1	7
0	1	0	0	0	8
0	1	0	0	1	9
0	1	0	1	0	10
0	1	0	1	1	11
0	1	1	0	0	12
0	1	1	0	1	13
0	1	1	1	0	14
0	1	1	1	1	15
1	0	0	0	0	16
1	0	0	0	1	17
1	0	0	1	0	18
1	0	0	1	1	19
1	0	1	0	0	20
1	0	1	0	1	21
1	0	1	1	0	22
1	0	1	1	1	23
1	1	0	0	0	24
1	1	0	0	1	25
1	1	0	1	0	26
1	1	0	1	1	27
1	1	1	0	0	28
1	1	1	0	1	29
1	1	1	1	0	30
1	1	1	1	1	31

En la tabla anterior se representa con “1” cuando el dispositivo este encendido, mientras que con cero cuando el dispositivo esta apagado.

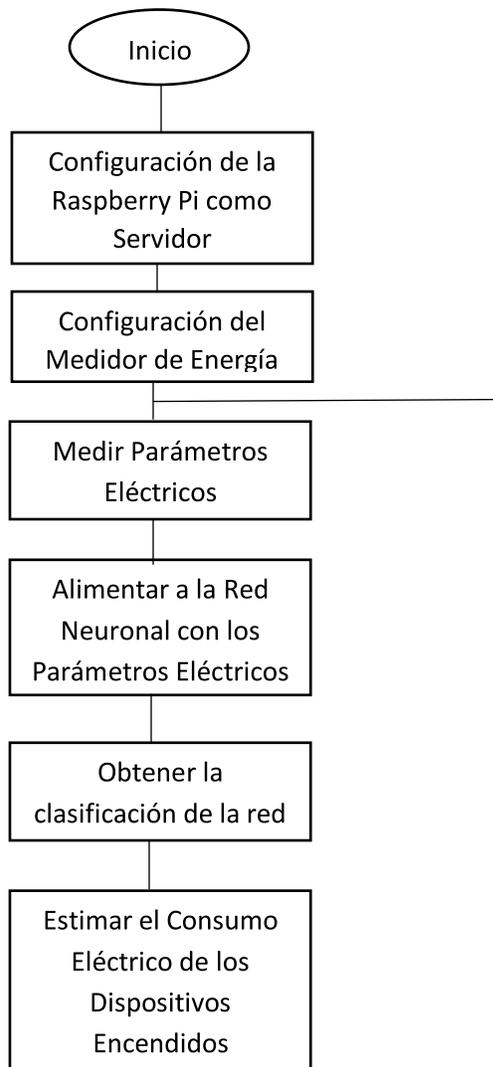
La programación tanto de la red neuronal como del entrenamiento de la misma se encuentra contenida en la clase `Multilayer_Network`. Esta clase consta de tres funciones:

- **Función `Network_Model`:** Esta contiene la parametrización de nuestra red a utilizar, como entradas tiene:
 - Número de neuronas ocultas en la capa oculta.
 - Función de Activación por utilizarse.
 - Máximo Número de Iteraciones hasta converger.
 - Función de Optimización para utilizarse.

Y nos devuelve una red ya parametrizada llamada `model`.

- **Función Training:** Permite coger de forma aleatoria los datos de entrenamiento, así como los datos de prueba. En nuestro caso se tomará 70% como datos de entrenamiento y 30% como datos de prueba. Además, permite el entrenamiento mediante la librería fit para luego guardar la red resultante en un archivo que se usara para clasificar nuestros dispositivos. Como entradas la función tiene:
 - La red parametrizada resultante de la función Network_Model.
 - Nombre del archivo en el que se almacenara la red ya entrenada.
- **Función Prediction:** Toma la red entrenada almacenado en un archivo por la función Training para alimentarla con nuestros parámetros eléctricos, con lo que nuestras salidas serán las clases propuestas en la tabla 3.1. Como entradas la función tiene:
 - Parámetros Eléctricos Medidos de la Red
 - Nombre del archivo en el que se almaceno la red entrenada.

A continuación, se presenta el diagrama de flujo del programa de monitoreo que incluye la red artificial.



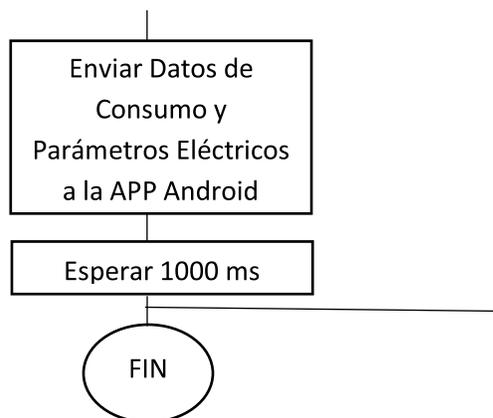


Figura 2.7 Diagrama de Flujo del Programa de Monitoreo

2.4 ENTRENAMIENTO DE LA RED NEURONAL

El entrenamiento de la red se lo realizó en un sistema distinto al Raspbian de la Raspberry Pi. En este caso se usó una laptop Core I3 con Sistema Operativo Windows 10, el uso de este equipo se hizo para asegurar rapidez en el entrenamiento. Además, también se entrenó usando servicios de procesamiento en la nube como es Google Colab, más sin embargo no hubo una mejoría notoria en el tiempo de entrenamiento.

Debido a que no existe una configuración única de la red neuronal que garantice la mejor clasificación, se entrenó alrededor de cincuenta ocasiones. Escogiendo como red para nuestra aplicación la que presentaba una mayor disminución de la función de error en el entrenamiento.

Para el entrenamiento de la red se recolectó mediciones de voltaje, corriente, potencia activa y potencia aparente de los dispositivos a clasificar. De cada uno de estos se tomó diez mil mediciones de los parámetros antes descritos, estas fueron tomadas en distintas horas del día para asegurar un mejor desempeño de la red.

2.5 APLICACIÓN ANDROID

Para el desarrollo de la aplicación Android se ha utilizado como IDE el software Android Studio, el mismo que como lenguaje nativo tiene a la codificación Java. Dado que no se ha tenido experiencia ni estudios previos para programación ni en este IDE ni en su lenguaje nativo, se ha utilizado partes de distintas codificaciones que se pueden encontrar en la web y se los ha adaptado a nuestro tema en desarrollo.

2.5.1 ANDROID STUDIO

Como muchos softwares de desarrollo, Android Studio incluye los servicios y herramientas necesarias para que un desarrollador cree nuevas aplicaciones. Entre dichas herramientas están las necesarias para crear la lógica (código), así como para crear la interfaz de usuario. Este IDE está basado en el software IntelliJ IDEA de JetBrains y está disponible para distintas plataformas, pero está diseñado para desarrollar específicamente Android. A continuación, se detalla algunas características de la versión más estable a la fecha.

- Soporte para la construcción basada en GRADLE
- Refactorización específica de Android y arreglos rápidos
- Herramientas Lint para detectar problemas de rendimiento usabilidad, compatibilidad de versiones y otros problemas.
- Integración de ProGuard y funciones de firma de aplicaciones.
- Plantillas para crear diseños comunes de Android y otros componentes.
- Editor de diseño que permite a los usuarios arrastrar y soltar componentes de la interfaz de usuario.
- Soporte para aplicaciones Android Wear.
- Dispositivo virtual Android que sirve para probar las aplicaciones.
- Renderización en tiempo real.
- Consola de Desarrollador.

En la gráfica siguiente podemos visualizar el entorno de Android Studio 2.2.3 en el que hemos desarrollado nuestra aplicación.

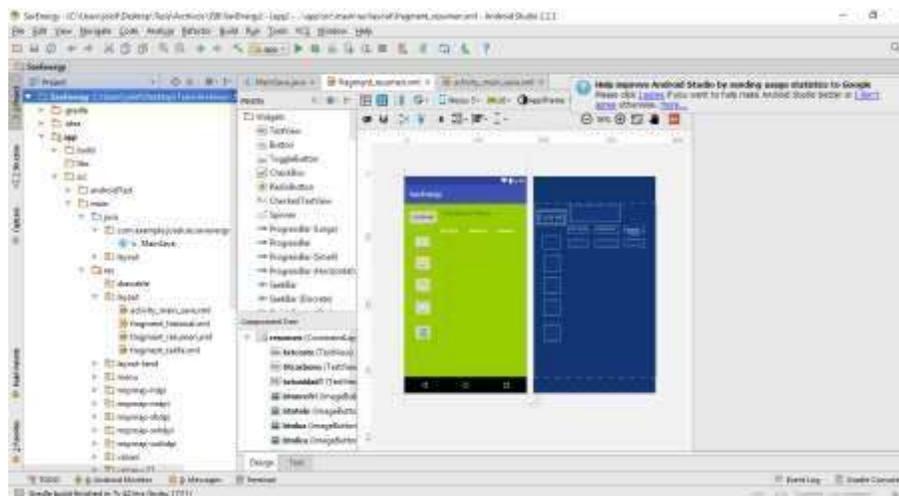


Figura 2.8 Entorno de Android Studio 2.2.3

2.5.2 DESARROLLO DE LA APLICACIÓN SAVENERGY

El desarrollo de la App que permita realimentar de información útil al usuario, ha representado un reto. Ya sea por la inexperticia en el desarrollo de la misma, tanto como por la dificultad del lenguaje java. Estas dificultades se han solventado de apoco con horas de programación, así como con la basta información que se puede encontrar sobre el tópico en la red.

En el desarrollo de SavEnergy se ha optado por la simplicidad de presentación de los datos, así como por la simplicidad en el protocolo de comunicación Raspberry Pi- APP. Lo cual nos permite tener una actualización de los datos a mostrar mucho más rápida, y nos ahorra recursos computacionales.

La pantalla principal de nuestra aplicación muestra con claridad parámetros relevantes de la red eléctrica como voltaje RMS, además de mostrar parámetros importantes de consumo como corriente RMS y potencia activa. Así también muestra que dispositivo está encendido y su consumo estimado de potencia activa.

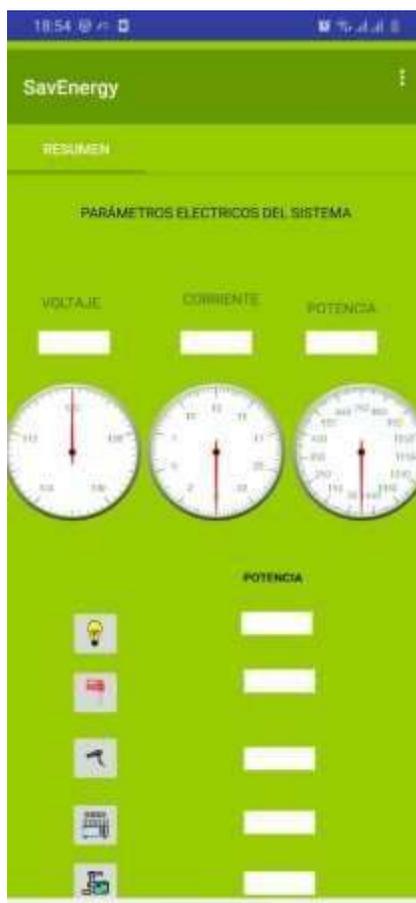


Figura 2.9 Pantalla App SavEnergy.

3. RESULTADOS Y DISCUSIÓN

Luego de la implementación de nuestro sistema NILM, nos compete el análisis de los resultados que se han obtenido posterior a probar nuestro sistema. Para poder evaluar las mediciones que realiza nuestro medidor de energía implementado, necesitamos de un medidor de referencia. En nuestro proyecto se ha usado el mismo medidor usado para calibrar.

Con las mediciones tanto de nuestra implementación como del medidor de referencia, podemos obtener indicadores estadísticos. Estos indicadores nos servirán para evaluar el desempeño de nuestro diseño. Además, al elaborar gráficas con estos datos podremos observar claramente, cuanto se asemejan las mediciones de nuestro medidor con el de referencia.

Otro aspecto importante de este capítulo, será presentar los resultados del funcionamiento de nuestra red neuronal. Para tal fin se elaborará una matriz de confusión, para visualizar de manera más sencilla la clasificación realizada por nuestra red neuronal.

3.1 RESULTADOS MEDIDOR DE ENERGÍA

En cuanto al diseño del medidor de energía, se probó distintos métodos. Entre estos, usar chips que conviertan un valor RMS en un equivalente DC, para obtener el valor digital de voltaje y corriente mediante un microcontrolador. Sin embargo, se comprobó que era un método poco práctico y que no optimiza ni el tiempo ni el dinero invertido en el diseño.

Así, se llegó a utilizar un circuito integrado especializado en medición de energía, específicamente el ADE7753, que es calibrado inicialmente mediante comunicación serial. Pero además en nuestro proyecto se ha realizado una calibración adicional en el programa principal de monitoreo. Esta calibración resulta bastante más sencilla que la calibración que sugiere el fabricante modificando los registros del circuito integrado.

Una vez implementado nuestro medidor de energía que usa un circuito integrado ADE7753, se ha tomado los datos que nos proporciona de los distintos parámetros a usar. Los cuales son: voltaje RMS, corriente RMS, potencia activa, potencia aparente.

Además, con los datos tomados de los medidores tanto diseñado como implementado, se calcula los indicadores estadísticos que son: Varianza, Covarianza, Desviación Estándar y Regresión Lineal.

Estos indicadores nos permitirán conocer, la relación entre las mediciones del equipo de referencia y el equipo implementado. En el caso de la varianza, nos indicara la variabilidad

de nuestros datos respecto a la media de los mismos. La covarianza nos indicará el grado de variación conjunta de los datos de nuestros dos medidores respecto a sus medias. Con la Desviación Estándar podremos cuantificar la variación o la dispersión de un conjunto de datos numéricos. Por último, el coeficiente de determinación nos permitirá saber cuan semejante son las mediciones del medidor implementado respecto al medidor referencia.

Con este precedente, a continuación, presentamos los datos tomados de mediciones con distintas cargas, así como las gráficas de los mismos. Además de los valores de los indicadores estadísticos antes descritos.

Tabla 3.1 Lecturas de Voltaje del medidor diseñado y medidor patrón

Medidor Diseñado (V)	Medidor Patrón (V)	Error %
111.70	111.90	0.18
114.30	114.60	0.26
115.80	116.20	0.35
117.10	117.50	0.34
117.40	117.80	0.34
118.10	118.40	0.25
111.70	111.90	1.79

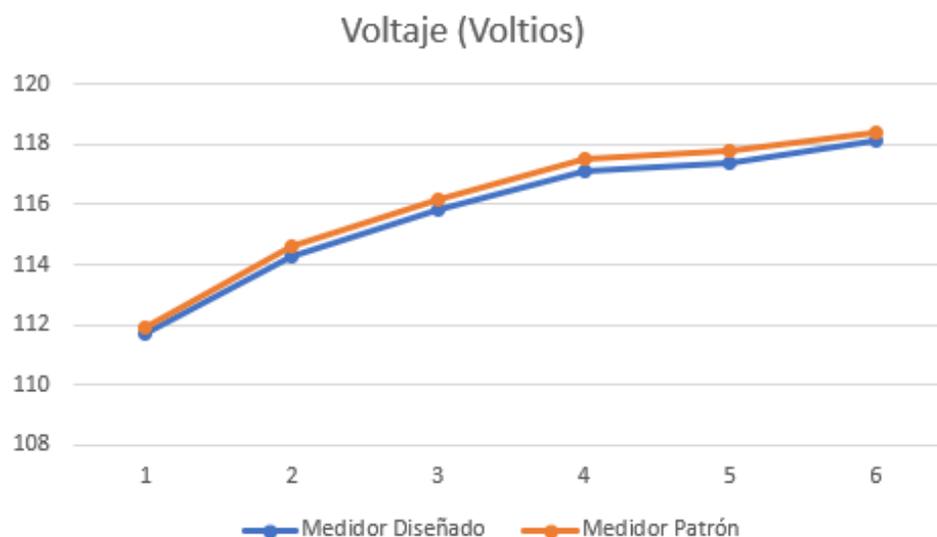


Figura 3.1 Comparativa de lecturas de voltaje entre medidor diseñado y medidor patrón.

Realizando el cálculo de los distintos parámetros estadísticos se tiene que:

- La varianza es: $5.36 V^2$ lo que nos indica que se ha recogido datos variados y no repetitivos.
- La covarianza es: $5.86 V^2$. Analizando la covarianza tenemos que las dos mediciones tienen comportamientos similares, esto nos indica el valor positivo de la covarianza. Es decir, valores grandes de voltaje del medidor de referencia se corresponden con valores grandes de voltaje del medidor implementado, de igual forma sucede con los valores pequeños.
- La desviación estándar es: $0.20 V$. Esto nos indica que la variación de la medición de voltaje del medidor implementado será de $0.20 V$ respecto a la medición de referencia.
- El coeficiente de determinación (R^2) es: 0.99 . El coeficiente de determinación nos indica que las dos mediciones presentan prácticamente los mismos valores, además el valor positivo de este coeficiente indica que las mediciones tienen una relación directamente proporcional.

La siguiente magnitud que se analizará será la corriente, misma que se muestra en la tabla a continuación:

Tabla 3.2 Lecturas de Corriente del medidor diseñado y medidor patrón

Medidor Diseñado (A)	Medidor Patrón (A)	Error %
0.30	0.31	2.30
0.76	0.79	3.20
1.03	1.04	1.80
1.77	1.78	0.80
3.49	3.54	1.40
3.53	3.57	1.10
7.04	7.15	1.50

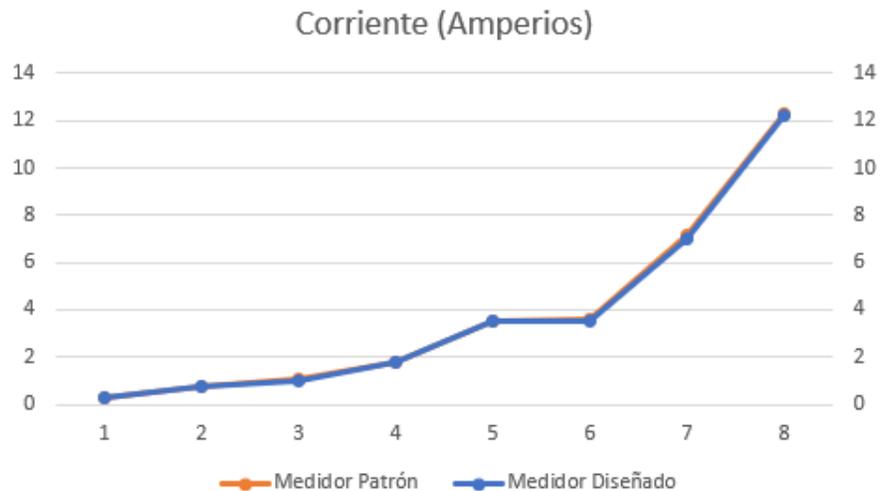


Figura 3.2 Comparativa de lecturas de corriente entre medidor diseñado y medidor patrón.

Realizando el cálculo de los distintos parámetros estadísticos se tiene que:

- La varianza es: $15.40 A^2$. Como análisis de este parámetro podemos decir que los valores de corriente que se ha medido han sido variados y están dispersos en un rango no muy grande de valores respecto a la media de medición de corriente.
- La covarianza es: $16.50 A^2$. Al ser positiva la covarianza, se concluye que las mediciones tienen un comportamiento similar. Es decir, mediciones grandes de corriente de medidor implementado se corresponden con mediciones grandes de referencia. De la misma forma pasa con las mediciones pequeñas.
- La desviación estándar es: $0.05 A$. Este valor nos indica que las mediciones de corriente del medidor implementado variaran alrededor de $0.05 A$ respecto a la medición de referencia.
- El coeficiente de determinación (R^2) es: 0.99 . Este valor de correlación nos indica que las mediciones de corriente tanto del medidor implementado como el de referencia son altamente similares.

Otra de los parámetros eléctricos usados en nuestro proyecto es la potencia activa, a continuación, se presenta los datos leídos tanto del medidor diseñado como del medidor patrón.

Tabla 3.3 Lecturas de Potencia Activa del medidor diseñado y medidor patrón

Medidor Diseñado (W)	Medidor Patrón (W)	Error %
38.78	37.00	4.80
95.51	93.00	2.70
115.00	112.00	2.60
216.23	213.00	1.50
427.68	422.00	1.30
832.04	829.00	0.40
926.03	922.00	0.40
1013.00	1017.00	0.40

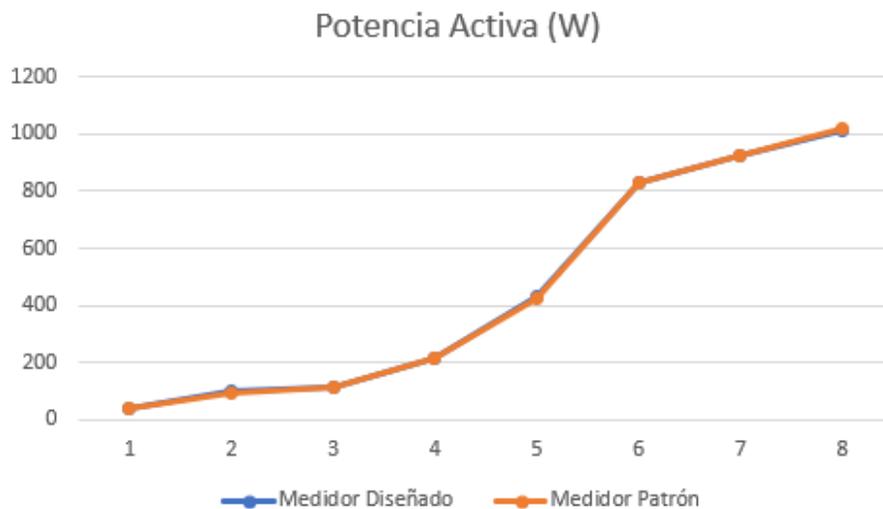


Figura 3.3 Comparativa de lecturas de potencia activa entre medidor diseñado y medidor patrón.

Realizando el cálculo de los distintos parámetros estadísticos se tiene que:

- La varianza es: $164854.86 W^2$. La varianza en este caso nos indica que las mediciones tomadas están dentro de un rango grande de valores de potencia.
- La covarianza es: $153869.83 W^2$. El valor positivo de la covarianza nos indica que las mediciones de potencia de nuestros medidores implementado y de referencia son similares.
- La desviación estándar es: $1.52 W$. La desviación estándar en el caso de la potencia, indican que las mediciones de potencia de nuestra implementación tendrán una variación de $1.52 W$ respecto a la medición de referencia.

El coeficiente de determinación (R^2) es: 0.99. De la misma forma que los casos anteriores, este valor de correlación indica que las mediciones de potencia de nuestros medidores en análisis son altamente similares.

El último de los parámetros que utilizamos para nuestro proyecto es la potencia aparente, en la siguiente tabla se puede observar lecturas de dicho parámetro:

Tabla 3.4 Lecturas de Potencia Aparente del medidor diseñado y medidor patrón

Medidor Diseñado (VA)	Medidor Patrón (VA)	Error %
38.91	37.00	5.20
95.00	92.00	3.30
214.00	209.00	2.40
306.00	300.00	2.00
422.71	418.00	0.90
826.00	820.00	0.70
1006.00	1000.00	0.60

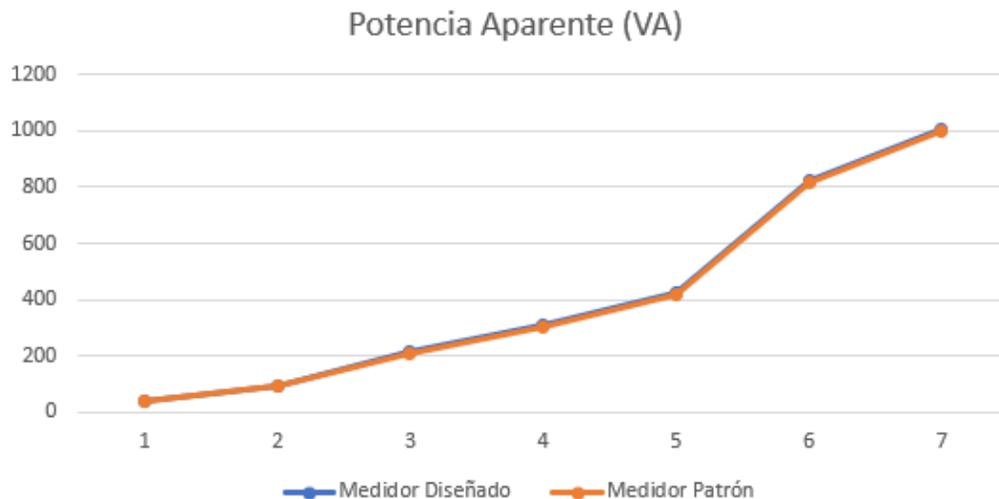


Figura 3.4 Comparativa de lecturas de potencia activa entre medidor diseñado y medidor patrón.

Realizando el cálculo de los distintos parámetros estadísticos se tiene que:

La varianza es: 115962.44 (VA)². El valor grande de varianza nos indica que las mediciones a analizar están dentro de un rango grande de valores.

- 📊 La covarianza es: 115955.88 $(VA)^2$. La covarianza nos indica que las mediciones de nuestros medidores a comparar tienen un comportamiento similar. Es decir, los valores grandes se corresponden entre sí, de igual forma sucede con los valores pequeños.
- 📊 La desviación estándar es: 3.00 VA. Este valor de desviación estándar nos indica que la medición de potencia aparente de nuestra implementación variará alrededor de 3. VA respecto a la medición de referencia
- 📊 El coeficiente de determinación (R^2) es: 0.99. El valor cercano a la unidad del coeficiente de correlación lineal nos indica que las mediciones de potencia aparente de los medidores a comparar son altamente similares

3.2 RESULTADOS RED NEURONAL ARTIFICIAL

Después de implementar nuestro sistema NILM, observamos que no se ha necesitado de más de una capa oculta para que la clasificación que realiza la red neuronal disminuya los falsos positivos y falsos negativos. Siendo eso sí, necesarios miles de neuronas en la capa oculta para que la clasificación sea óptima. Más no significa que entre más neuronas tenga la red, el comportamiento de la misma será mejor. Pues podría llegar un punto en que la red pierda su capacidad de generalización y únicamente memorice.

También se ha visualizado claramente, que una red neuronal únicamente puede realizar agrupamiento (clustering) o clasificación (classification). En nuestro caso particular al ser necesario clasificar eventos, se realizó un entrenamiento supervisado.

Por otro lado, las neuronas de una red tienen funciones de activación, la misma que debe ser escogida de acuerdo a la salida que deseamos. Para nosotros que tenemos salidas entre cero y uno, la ideal fue la función logística. Más no significa que no podamos escoger funciones que tengan otro rango de salidas. Pero en nuestras pruebas, el escoger de manera errónea la función de activación tuvo como consecuencia la lenta disminución de la función de error, así como, un mayor tiempo de aprendizaje.

La disminución lenta de la función de error se puede solventar usando mayores recursos computacionales para el entrenamiento, en la web existen un sin número de opciones. Uno de estos es Google Colab, que ofrece la posibilidad de entrenar una red usando GPU's o TPU's. Sin embargo, la versión gratuita tiene un tiempo límite de entrenamiento y la versión paga solo está disponible en Estados Unidos de Norte América.

En nuestro caso, únicamente se usó el entrenamiento en la nube para probar los resultados de entrenar con una cantidad alta de neuronas en la capa oculta o con dos capas ocultas.

Luego de entrenamiento, para analizar el comportamiento de la red neuronal desarrollada, se hace necesario presentar los datos de clasificación en una matriz de confusión. Además de indicadores estadísticos del performance de la clasificación. Para un mejor entendimiento de cada indicador a continuación listaremos el indicador con su interpretación del performance del clasificador.

- Exactitud: porcentaje de predicciones correctas
- Precisión: porcentaje de predicciones positivas correctas
- Sensibilidad: porcentaje de casos positivos detectados
- Especificidad: porcentaje de casos negativos detectados

Para desarrollar las matrices de confusión se probó el sistema diecisiete veces, lo que nos arrojó los siguientes resultados.

Tabla 3.5 Matriz de confusión del Dispositivo Lámpara.

Lámpara		Valor Real	
		True	False
Valor Predicho	True	5	2
	False	2	8

Tabla 3.6 Indicadores Estadísticos de la Clasificación del Dispositivo Lámpara.

Lámpara	Precisión	Sensibilidad	Exactitud	Especificidad
	0,71	0,71	0,76	0,80

Tabla 3.7 Matriz de confusión del Dispositivo Batidora.

Batidora		Valor Real	
		True	False
Valor Predicho	True	5	0
	False	1	11

Tabla 3.8 Indicadores Estadísticos de la Clasificación del Dispositivo Batidora.

Batidora	Precisión	Sensibilidad	Exactitud	Especificidad
	1,00	0,83	0,94	1,00

Tabla 3.9 Matriz de confusión del Dispositivo Calefactor.

Calefactor		Valor Real	
		True	False
Valor Predicho	True	5	0
	False	5	7

Tabla 3.10 Datos Estadísticos del Dispositivo Calefactor.

Calefactor	Precisión	Sensibilidad	Exactitud	Especificidad
	1,00	0,50	0,71	1,00

Tabla 3.11 Matriz de confusión del Dispositivo Molino.

Molino		Valor Real	
		True	False
Valor Predicho	True	7	3
	False	1	6

Tabla 3.12 Indicadores Estadísticos de la Clasificación del Dispositivo Molino.

Molino	Precisión	Sensibilidad	Exactitud	Especificidad
	0,70	0,88	0,76	0,67

Tabla 3.13 Matriz de confusión del Dispositivo Secadora.

Secadora		Valor Real	
		True	False
Valor Predicho	True	4	2
	False	3	8

Tabla 3.14 Indicadores Estadísticos de la Clasificación del Dispositivo Secadora.

Secadora	Precisión	Sensibilidad	Exactitud	Especificidad
	0,67	0,57	0,71	0,80

De la Matriz de Confusión se desprende que, en el desarrollo del proyecto existen un sin número de inconvenientes que necesitan ser observados y revisados. Entre estos están la limitación de diseño del algoritmo en un ambiente residencial. Adicionalmente los ocupantes deben ser persuadidos a la conservación de la energía para que el sistema trabaje, lo cual se pretende lograr presentándoles datos convenientes y persuasivos.

Ahora ya enfocándonos en los algoritmos NILM residenciales, existen algunas limitantes que deben ser consideradas para que se considere que la retroalimentación de la información es exitosa. Así, también algunos autores han identificado seis restricciones al espacio de solución de NILM residenciales, estas son: selección de la característica a analizar, precisión, entrenamiento, escalabilidad y que sea válido para varios tipos de dispositivos [11].

Estas restricciones son vitales en el desarrollo de tecnologías NILM, pues el observar cada una con detenimiento nos permitirá optimizar el tiempo de implementación del sistema. Especialmente la selección de la característica adecuada de acuerdo al tipo de carga es fundamental.

En cuanto a la escalabilidad, se puede mencionar que se necesita una muestra de mediciones lo suficientemente representativa para que nuestro dispositivo pueda funcionar con una gran cantidad de dispositivos. Actualmente existen datasets disponibles para desarrollar equipos NILM, sin embargo, su costo es elevado pues se requiere una considerable cantidad de tiempo y recursos tanto económicos como computacionales para su elaboración.

Finalmente, a pesar de las limitaciones varias, nuestro dispositivo ha desagregado la potencia activa e identificado las cinco cargas propuestas con una precisión apreciable. Lo que supone el final exitoso de nuestro proyecto.

3.3 RESTRICCIONES Y LIMITACIONES

Luego de observar los resultados de nuestra implementación, se han observado algunas restricciones en el funcionamiento de nuestro sistema de monitoreo de carga no intrusiva. A continuación, se listarán las mismas:

- La clasificación de dispositivos con similares consumos de potencia es altamente inexacta usando únicamente los parámetros voltaje, potencia activa, corriente y potencia aparente como entradas de una red neuronal artificial.
- Si la sumatoria del consumo de potencia de varios dispositivos es similar al consumo de potencia de otro dispositivo a clasificar, la clasificación será altamente inexacta con el método de clasificación usado en este proyecto.
- Los dispositivos multi-estado incrementan grandemente el nivel de dificultad de entrenamiento de nuestra red con el método usado.
- Los dispositivos con consumo de potencia variable no se pueden clasificar con nuestra implementación
- Si dos dispositivos son del mismo tipo (ej. Taladros), pero con consumos de potencia bastante diferentes, se deben tratar como dos clases diferentes.
- La generalización resulta altamente compleja y costosa, pues se necesita tomar mediciones de parámetros eléctricos de una cantidad representativa del universo a clasificar.

4. CONCLUSIONES Y RECOMENDACIONES

4.1 CONCLUSIONES

Al estudiar el funcionamiento de un sistema de monitoreo de carga no intrusivo (Non-Intrusive Load Monitoring-NILM), podemos concluir que se fundamentan en la distinción de los distintos parámetros eléctricos medibles. En nuestro caso, los parámetros medidos se han utilizado como insumo de una red neuronal artificial usada para clasificar.

Con el fin de medir estos parámetros eléctricos seleccionados, se diseñó e implementó un sistema de medición de corriente alterna monofásico basado en el criterio de monitoreo de carga no intrusivo para la acometida de un sistema residencial. El mismo que presenta un comportamiento similar al medidor usado de referencia para calibrar.

Este medidor nos ha permitido realizar mediciones y análisis del comportamiento de consumo de las cargas eléctricas seleccionadas, al ser estas cargas prácticamente resistivas la desagregación de potencia resulta menos demandante que otros tipos de cargas. Además, por este motivo se ha elegido métodos en estado estable para desagregar la potencia consumida.

Así, al identificar las al menos cinco cargas eléctricas conectadas, para determinar su consumo energético y costo estimado de energía consumida. Se ha concluido que la parte más compleja no es la de identificar las cargas conectadas, sino inferir el consumo de potencia de cada uno de los aparatos identificados.

En cuanto, al desarrollo de una aplicación para sistema operativo Android que permita el monitoreo y visualización en línea del consumo de potencia y energía de las cargas eléctricas de una residencia. Se puede concluir que el desarrollo de App's es altamente demandante a nivel de programación, motivo por el cual su costo suele ser elevado. Además, al estar en actualización constante Android Studio, ciertas librerías y comandos suelen quedar obsoletas en cuestión de meses.

Ahora bien, en cuanto a los datos estadísticos obtenidos en el capítulo anterior, podemos tener las siguientes conclusiones. Primero analizando los valores de la covarianza obtenidos de los datos de los cuatro parámetros a medir, podemos establecer que tiene un comportamiento similar, tanto nuestra implementación como el equipo de referencia. La desviación estándar nos indica que la dispersión de los datos medidos es baja. En tanto el coeficiente de determinación nos indica que las mediciones de nuestro medidor de

parámetros eléctricos son muy similares a las que nos daría el medidor de parámetros referencia.

Finalmente, este trabajo ha demostrado que se puede desagregar la potencia activa de dispositivos domiciliarios usando redes neuronales artificiales, sin embargo, como toda tecnología tiene limitantes. Las mismas que son notorias cuando dispositivos de diferentes, tienen características similares en sus parámetros eléctricos. Así también, cuando un conjunto de dispositivos tiene parámetros de consumo energético similares a otro dispositivo.

4.1 RECOMENDACIONES

Las principales recomendaciones que se desprenden de este trabajo, nacen precisamente de sus limitaciones. Una de las principales es la dificultad de desagregar dispositivos con parámetros eléctricos similares usados como insumo de nuestra red neuronal. Para lo cual se sugiere en trabajos posteriores añadir la distorsión armónica como quinta entrada a la red neuronal. Dado que resulta menos probable que este parámetro sea similar en los dispositivos a desagregar.

Otro aspecto importante a tener en cuenta en trabajos futuros sería, no diseñar un medidor de energía. Más bien, adquirir uno fabricado en serie que tenga comunicación serial. De este modo se dedicaría más esfuerzo y tiempo al algoritmo de desagregación, así como al entrenamiento de la red neuronal.

También se sugeriría establecer con claridad que dispositivos se van a desagregar, y analizar previamente las características de consumo, así como otras firmas ya sean en estado estable o transitorio a utilizar. Pues dicha información optimiza muchos aspectos del desarrollo de tecnologías NILM.

Por otra parte, en el desarrollo de una aplicación para celular se recomendaría usar la última versión de Android Studio disponible, ya que este IDE tiene constantes actualizaciones y sus comandos pueden quedar obsoletos en cuestión de meses.

5. REFERENCIAS BIBLIOGRÁFICAS

- [1] G. W. Hart, "Nonintrusive Load Monitoring", *IEEE J*, vol. 80, no. 12, pp. 1-4, Dec. 1992.
- [2] A. Zoha, A. Gluhak, M. Imran and S. Rajasegarar, "Non-Intrusive Load Monitoring Approaches for Disaggregated Energy Sensing: A Survey", *Sensors Open Access*, ISSN 1424-8220, pp. 1-5, Dec. 2012.
- [3] S. Makonin, "Approaches to Non-Intrusive Load Monitoring (Nilm) In the Home," PhD. report, Faculty of Applied Sciences, British Columbia Inst., British Columbia, Canada, 2009.
- [4] Z. Wang, G. Zheng, "Residential appliances identification and monitoring by a non-intrusive method", *IEEE Trans. Smart Grid* 2012, 3, 80-92.
- [5] F. Izurieta, C. Saavedra, "Redes Neuronales Artificiales", unpublished.
- [6] R. Rojas, "Neural Networks", Springer-Verlag, Berlin, Germany, 1996
- [7] Texas Instrument, "Adquirir una Señal Analógica: Ancho de Banda, Teorema de Muestreo de Nyquist y Aliasing", [Online]. Available: <https://www.ti.com/es-cr/innovations/white-papers/06/acquiring-an-analog-signal--bandwidth--nyquist-sampling-theorem-.html>, Accesado en: Feb. 7, 2020
- [8] P. Larranaga, I. Inza, A/ Moujahid, "Redes Neuronales", País Vasco, España, [Online]. Available: <http://www.sc.ehu.es/ccw/bayes/docencia/mmcc/docs/t8neuronales.pdf>
- [9] *Single-Phase Multifunction Metering IC with di/dt Sensor Interface ADE7753*, Analog Devices Inc., Norwood, MA, 2010
- [10] Scikit-Learn Consortium at Inria Foundation, "Neural Network Models (Supervised)", [Online]. Available: https://scikit-learn.org/stable/modules/neural_networks_supervised.html#

ANEXOS

ANEXO A. Información Importante del Circuito Integrado ADE7753

ANEXO A



Single-Phase Multifunction Metering IC with di/dt Sensor Interface

ADE7753

FEATURES

- High accuracy; supports IEC 60687/61036/61268 and IEC 62053-21/62053-22/62053-23**
- On-chip digital integrator enables direct interface to current sensors with di/dt output**
- A PGA in the current channel allows direct interface to shunts and current transformers**
- Active, reactive, and apparent energy; sampled waveform; current and voltage rms**
- Less than 0.1% error in active energy measurement over a dynamic range of 1000 to 1 at 25°C**
- Positive-only energy accumulation mode available**
- On-chip user programmable threshold for line voltage surge and SAG and PSU supervisory**
- Digital calibration for power, phase, and input offset**
- On-chip temperature sensor ($\pm 3^\circ\text{C}$ typical)**
- SPI® compatible serial interface**
- Pulse output with programmable frequency**
- Interrupt request pin (IRQ) and status register**
- Reference 2.4V with external overdrive capability**
- Single 5V supply, low power (25 mW typical)**

GENERAL DESCRIPTION

The ADE7753¹ features proprietary ADCs and DSP for high accuracy over large variations in environmental conditions and time. The ADE7753 incorporates two second-order 16-bit $\Sigma\text{-}\Delta$ ADCs, a digital integrator (on CH1), reference circuitry, temperature sensor, and all the signal processing required to perform active, reactive, and apparent energy measurements.

line-voltage period measurement, and rms calculation on the voltage and current. The selectable on-chip digital integrator provides direct interface to di/dt current sensors such as Rogowski coils, eliminating the need for an external analog integrator and resulting in excellent long-term stability and precise phase matching between the current and voltage channels.

The ADE7753 provides a serial interface to read data, and a pulse output frequency (CF), which is proportional to the active power. Various system calibration features, i.e., channel offset correction, phase calibration, and power calibration, ensure high accuracy. The part also detects short duration low or high voltage variations.

The positive-only accumulation mode gives the option to accumulate energy only when positive power is detected. An internal no-load threshold ensures that the part does not exhibit any creep when there is no load. The zero-crossing output (ZX) produces a pulse that is synchronized to the zero-crossing point of the line voltage. This signal is used internally in the line cycle active and apparent energy accumulation modes, which enables faster calibration.

The interrupt status register indicates the nature of the interrupt, and the interrupt enable register controls which event produces an output on the IRQ pin, an open-drain, active low logic output.

The ADE7753 is available in a 20-lead SSOP package.

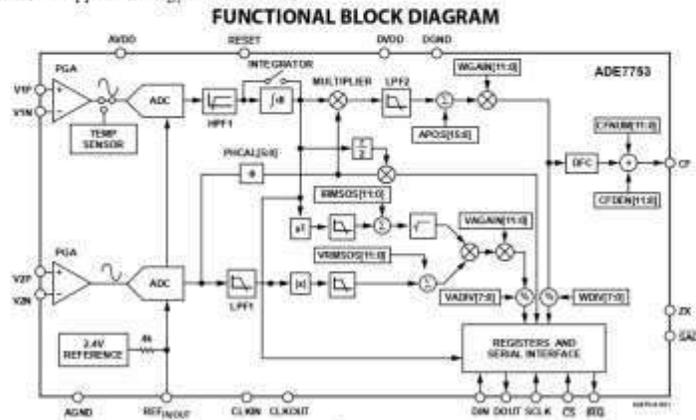


Figure 1.

¹U.S. Patents 5,745,323; 5,760,617; 5,862,069; 5,872,469.

Rev. C
Information furnished by Analog Devices is believed to be accurate and reliable. However, no responsibility is assumed by Analog Devices for its use, nor for any infringements of patents or other rights of third parties that may result from its use. Specifications subject to change without notice. No license is granted by implication or otherwise under any patent or patent rights of Analog Devices. Trademarks and registered trademarks are the property of their respective owners.

ADE7753

SPECIFICATIONS

$AV_{DD} = DV_{DD} = 5 V \pm 5\%$, $AGND = DGND = 0 V$, on-chip reference, $CLKIN = 3.579545 \text{ MHz XTAL}$, T_{MIN} to $T_{MAX} = -40^{\circ}\text{C}$ to $+85^{\circ}\text{C}$. See the plots in the Typical Performance Characteristics section.

Table 1.

Parameter	Spec	Unit	Test Conditions/Comments
ENERGY MEASUREMENT ACCURACY			
Active Power Measurement Error			
Channel 1 Range = 0.5 V Full Scale			
Gain = 1	0.1	% typ	CLKIN = 3.579545 MHz
Gain = 2	0.1	% typ	Channel 2 = 300 mV rms/60 Hz, gain = 2
Gain = 4	0.1	% typ	Over a dynamic range 1000 to 1
Gain = 8	0.1	% typ	Over a dynamic range 1000 to 1
Channel 1 Range = 0.25 V Full Scale			
Gain = 1	0.1	% typ	Over a dynamic range 1000 to 1
Gain = 2	0.1	% typ	Over a dynamic range 1000 to 1
Gain = 4	0.1	% typ	Over a dynamic range 1000 to 1
Gain = 8	0.2	% typ	Over a dynamic range 1000 to 1
Channel 1 Range = 0.125 V Full Scale			
Gain = 1	0.1	% typ	Over a dynamic range 1000 to 1
Gain = 2	0.1	% typ	Over a dynamic range 1000 to 1
Gain = 4	0.2	% typ	Over a dynamic range 1000 to 1
Gain = 8	0.2	% typ	Over a dynamic range 1000 to 1
Active Power Measurement Bandwidth	14	kHz	
Phase Error 1 between Channels ¹	± 0.05	max	Line Frequency = 45 Hz to 65 Hz, HPF on
AC Power Supply Rejection ¹			
Output Frequency Variation (CF)	0.2	% typ	$AV_{DD} = DV_{DD} = 5 V + 175 \text{ mV rms}/120 \text{ Hz}$
			Channel 1 = 20 mV rms, gain = 16, range = 0.5 V
			Channel 2 = 300 mV rms/60 Hz, gain = 1
DC Power Supply Rejection ²			
Output Frequency Variation (CF)	± 0.3	% typ	$AV_{DD} = DV_{DD} = 5 V \pm 250 \text{ mV dc}$
			Channel 1 = 20 mV rms/60 Hz, gain = 16, range = 0.5 V
			Channel 2 = 300 mV rms/60 Hz, gain = 1
IRMS Measurement Error	0.5	% typ	Over a dynamic range 100 to 1
IRMS Measurement Bandwidth	14	kHz	
VRMS Measurement Error	0.5	% typ	Over a dynamic range 20 to 1
VRMS Measurement Bandwidth	140	Hz	
ANALOG INPUTS²			
Maximum Signal Levels	± 0.5	V max	See the Analog Inputs section
Input Impedance (dc)	390	k min	V1P, V1N, V2N, and V2P to AGND
Bandwidth	14	kHz	
Gain Error ^{1, 2}			CLKIN/256, CLKIN = 3.579545 MHz
Channel 1			
Range = 0.5 V Full Scale	± 4	% typ	External 2.5 V reference, gain = 1 on Channels 1 and 2
Range = 0.25 V Full Scale	± 4	% typ	V1 = 0.5 V dc
Range = 0.125 V Full Scale	± 4	% typ	V1 = 0.25 V dc
Channel 2			
	± 4	% typ	V1 = 0.125 V dc
	± 4	% typ	V2 = 0.5 V dc
Offset Error ¹			
Channel 1	± 32	mV max	Gain 1
Channel 1	± 13	mV max	Gain 16
Channel 2	± 32	mV max	Gain 1
Channel 2	± 13	mV max	Gain 16
WAVEFORM SAMPLING			
Channel 1			
Signal-to-Noise Plus Distortion	62	dB typ	Sampling CLKIN/128, 3.579545 MHz/128 = 27.9 kSPS
Bandwidth(-3 dB)	14	kHz	See the Channel 1 Sampling section
			150 mV rms/60 Hz, range = 0.5 V, gain = 2
			CLKIN = 3.579545 MHz

Parameter	Spec	Unit	Test Conditions/Comments
Channel 2 Signal-to-Noise Plus Distortion Bandwidth (-3 dB)	60 140	dB typ Hz	See the Channel 2 Sampling section 150 mV rms/60 Hz, gain = 2 CLKIN = 3.579545 MHz
REFERENCE INPUT REF _{AVOUT} Input Voltage Range	2.6 2.2	V max V min	2.4 V + 8% 2.4 V - 8%
Input Capacitance	10	pF max	
ON-CHIP REFERENCE Reference Error	±200	mV max	Nominal 2.4 V at REF _{AVOUT} pin
Current Source	10	µA max	
Output Impedance	3.4	kΩ min	
Temperature Coefficient	30	ppm/°C typ	
CLKIN Input Clock Frequency	4 1	MHz max MHz min	All specifications CLKIN of 3.579545 MHz
LOGIC INPUTS RESET, DIN, SCLK, CLKIN, and CS			
Input High Voltage, V _{OH}	2.4	V min	DV _{DD} = 5 V ± 10%
Input Low Voltage, V _{OL}	0.8	V max	DV _{DD} = 5 V ± 10%
Input Current, I _{IN}	±3	µA max	Typically 10 nA, V _{IN} = 0V to DV _{DD}
Input Capacitance, C _{IN}	10	pF max	
LOGIC OUTPUTS SAG and IRQ			Open-drain outputs, 10 kΩ pull-up resistor
Output High Voltage, V _{OH}	4	V min	I _{SOURCE} = 5 mA
Output Low Voltage, V _{OL}	0.4	V max	I _{SENSE} = 0.8 mA
ZX and DOUT			
Output High Voltage, V _{OH}	4	V min	I _{SOURCE} = 5 mA
Output Low Voltage, V _{OL}	0.4	V max	I _{SENSE} = 0.8 mA
CF			
Output High Voltage, V _{OH}	4	V min	I _{SOURCE} = 5 mA
Output Low Voltage, V _{OL}	1	V max	I _{SENSE} = 7 mA
POWER SUPPLY AVDD	4.75 5.25	V min V max	For specified performance 5 V - 5% 5 V + 5%
DVDD	4.75 5.25	V min V max	5 V - 5% 5 V + 5%
I _{AVDD}	3	mA max	Typically 2.0 mA
I _{DVDD}	4	mA max	Typically 3.0 mA

¹ See the Terminology section for explanation of specifications.

² See the Analog Inputs section.

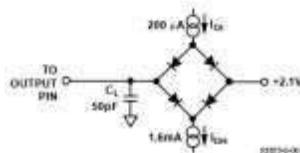


Figure 2. Load Circuit for Timing Specifications

PIN CONFIGURATION AND FUNCTION DESCRIPTIONS

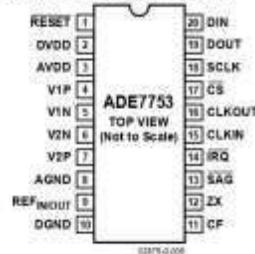


Figure 5. Pin Configuration (SSOP Package)

Table 4. Pin Function Descriptions

Pin No.	Mnemonic	Description
1	RESET	Reset Pin for the ADE7753. A logic low on this pin holds the ADCs and digital circuitry (including the serial interface) in a reset condition.
2	DVDD	Digital Power Supply. This pin provides the supply voltage for the digital circuitry in the ADE7753. The supply voltage should be maintained at $5\text{ V} \pm 5\%$ for specified operation. This pin should be decoupled to DGND with a $10\ \mu\text{F}$ capacitor in parallel with a ceramic $100\ \text{nF}$ capacitor.
3	AVDD	Analog Power Supply. This pin provides the supply voltage for the analog circuitry in the ADE7753. The supply should be maintained at $5\text{ V} \pm 5\%$ for specified operation. Every effort should be made to minimize power supply ripple and noise at this pin by the use of proper decoupling. The typical performance graphs show the power supply rejection performance. This pin should be decoupled to AGND with a $10\ \mu\text{F}$ capacitor in parallel with a ceramic $100\ \text{nF}$ capacitor.
4, 5	V1P, V1N	Analog Inputs for Channel 1. This channel is intended for use with a di/dt current transducer such as a Rogowski coil or another current sensor such as a shunt or current transformer (CT). These inputs are fully differential voltage inputs with maximum differential input signal levels of $\pm 0.5\text{ V}$, $\pm 0.25\text{ V}$, and $\pm 0.125\text{ V}$, depending on the full-scale selection—see the Analog Inputs section. Channel 1 also has a PGA with gain selections of 1, 2, 4, 8, or 16. The maximum signal level at these pins with respect to AGND is $\pm 0.5\text{ V}$. Both inputs have internal ESD protection circuitry, and, in addition, an overvoltage of $\pm 6\text{ V}$ can be sustained on these inputs without risk of permanent damage.
6, 7	V2N, V2P	Analog Inputs for Channel 2. This channel is intended for use with the voltage transducer. These inputs are fully differential voltage inputs with a maximum differential signal level of $\pm 0.5\text{ V}$. Channel 2 also has a PGA with gain selections of 1, 2, 4, 8, or 16. The maximum signal level at these pins with respect to AGND is $\pm 0.5\text{ V}$. Both inputs have internal ESD protection circuitry, and an overvoltage of $\pm 6\text{ V}$ can be sustained on these inputs without risk of permanent damage.
8	AGND	Analog Ground Reference. This pin provides the ground reference for the analog circuitry in the ADE7753, i.e., ADCs and reference. This pin should be tied to the analog ground plane or the quietest ground reference in the system. This quiet ground reference should be used for all analog circuitry, for example, anti-aliasing filters, current and voltage transducers, etc. To keep ground noise around the ADE7753 to a minimum, the quiet ground plane should be connected to the digital ground plane at only one point. It is acceptable to place the entire device on the analog ground plane.
9	REF _{IN/OUT}	Access to the On-Chip Voltage Reference. The on-chip reference has a nominal value of $2.4\text{ V} \pm 8\%$ and a typical temperature coefficient of $30\ \text{ppm}/^\circ\text{C}$. An external reference source can also be connected at this pin. In either case, this pin should be decoupled to AGND with a $1\ \mu\text{F}$ ceramic capacitor.
10	DGND	Digital Ground Reference. This pin provides the ground reference for the digital circuitry in the ADE7753, i.e., multiplier, filters, and digital-to-frequency converter. Because the digital return currents in the ADE7753 are small, it is acceptable to connect this pin to the analog ground plane of the system. However, high bus capacitance on the DOUT pin could result in noisy digital current, which could affect performance.
11	CF	Calibration Frequency Logic Output. The CF logic output gives active power information. This output is intended to be used for operational and calibration purposes. The full-scale output frequency can be adjusted by writing to the CFDEN and CFNUM registers—see the Energy-to-Frequency Conversion section.

ADE7753

Pin No.	Mnemonic	Description
12	ZX	Voltage Waveform (Channel 2) Zero-Crossing Output. This output toggles logic high and logic low at the zero crossing of the differential signal on Channel 2—see the Zero-Crossing Detection section.
13	$\overline{\text{SAG}}$	This open-drain logic output goes active low when either no zero crossings are detected or a low voltage threshold (Channel 2) is crossed for a specified duration—see the Line Voltage Sag Detection section.
14	$\overline{\text{IRQ}}$	Interrupt Request Output. This is an active low open-drain logic output. Maskable interrupts include active energy register rollover, active energy register at half level, and arrivals of new waveform samples—see the ADE7753 Interrupts section.
15	CLKIN	Master Clock for ADCs and Digital Signal Processing. An external clock can be provided at this logic input. Alternatively, a parallel resonant AT crystal can be connected across CLKIN and CLKOUT to provide a clock source for the ADE7753. The clock frequency for specified operation is 3.579545 MHz. Ceramic load capacitors of between 22 pF and 33 pF should be used with the gate oscillator circuit. Refer to the crystal manufacturer's data sheet for load capacitance requirements.
16	CLKOUT	A crystal can be connected across this pin and CLKIN as described for Pin 15 to provide a clock source for the ADE7753. The CLKOUT pin can drive one CMOS load when either an external clock is supplied at CLKIN or a crystal is being used.
17	$\overline{\text{CS}}$	Chip Select. Part of the 4-wire SPI serial interface. This active low logic input allows the ADE7753 to share the serial bus with several other devices—see the ADE7753 Serial Interface section.
18	SCLK	Serial Clock Input for the Synchronous Serial Interface. All serial data transfers are synchronized to this clock—see the ADE7753 Serial Interface section. The SCLK has a Schmitt-trigger input for use with a clock source that has a slow edge transition time, for example, opto-isolator output.
19	DOUT	Data Output for the Serial Interface. Data is shifted out at this pin on the rising edge of SCLK. This logic output is normally in a high impedance state unless it is driving data onto the serial data bus—see the ADE7753 Serial Interface section.
20	DIN	Data Input for the Serial Interface. Data is shifted in at this pin on the falling edge of SCLK—see the ADE7753 Serial Interface section.

¹ It is recommended to drive the RESET, SCLK, and $\overline{\text{CS}}$ pins with either a push-pull without an external series resistor or with an open-collector with a 10 k Ω pull-up resistor. Pull-down resistors are not recommended because under some conditions, they may interact with internal circuitry.

ADE7753

ADE7753 REGISTERS

Table 12. Summary of Registers by Address

Address	Name	R/W	No. Bits	Default	Type ¹	Description
0x01	WAVEFORM	R	24	0x0	S	Waveform Register. This read-only register contains the sampled waveform data from either Channel 1, Channel 2, or the active power signal. The data source and the length of the waveform registers are selected by data Bits 14 and 13 in the mode register—see the Channel 1 Sampling and Channel 2 Sampling sections.
0x02	AENERGY	R	24	0x0	S	Active Energy Register. Active power is accumulated (integrated) over time in this 24-bit, read-only register—see the Energy Calculation section.
0x03	RAENERGY	R	24	0x0	S	Same as the active energy register except that the register is reset to 0 following a read operation.
0x04	LAENERGY	R	24	0x0	S	Line Accumulation Active Energy Register. The instantaneous active power is accumulated in this read-only register over the LINECYC number of half line cycles.
0x05	VAENERGY	R	24	0x0	U	Apparent Energy Register. Apparent power is accumulated over time in this read-only register.
0x06	RVAENERGY	R	24	0x0	U	Same as the VAENERGY register except that the register is reset to 0 following a read operation.
0x07	LVAENERGY	R	24	0x0	U	Line Accumulation Apparent Energy Register. The instantaneous real power is accumulated in this read-only register over the LINECYC number of half line cycles.
0x08	LVARENERGY	R	24	0x0	S	Line Accumulation Reactive Energy Register. The instantaneous reactive power is accumulated in this read-only register over the LINECYC number of half line cycles.
0x09	MODE	R/W	16	0x000C	U	Mode Register. This is a 16-bit register through which most of the ADE7753 functionality is accessed. Signal sample rates, filter enabling, and calibration modes are selected by writing to this register. The contents can be read at any time—see the Mode Register (0x9) section.
0x0A	IRQEN	R/W	16	0x40	U	Interrupt Enable Register. ADE7753 interrupts can be deactivated at any time by setting the corresponding bit in this 16-bit enable register to Logic 0. The status register continues to register an interrupt event even if disabled. However, the IRQ output is not activated—see the ADE7753 Interrupts section.
0x0B	STATUS	R	16	0x0	U	Interrupt Status Register. This is an 16-bit read-only register. The status register contains information regarding the source of ADE7753 interrupts—the see ADE7753 Interrupts section.
0x0C	RSTSTATUS	R	16	0x0	U	Same as the interrupt status register except that the register contents are reset to 0 (all flags cleared) after a read operation.
0x0D	CH1OS	R/W	8	0x00	S ¹	Channel 1 Offset Adjust. Bit 6 is not used. Writing to Bits 0 to 5 allows offsets on Channel 1 to be removed—see the Analog Inputs and CH1OS Register (0x0D) sections. Writing a Logic 1 to the MSB of this register enables the digital integrator on Channel 1, a Logic 0 disables the integrator. The default value of this bit is 0.
0x0E	CH2OS	R/W	8	0x0	S ¹	Channel 2 Offset Adjust. Bits 6 and 7 are not used. Writing to Bits 0 to 5 of this register allows any offsets on Channel 2 to be removed—see the Analog Inputs section. Note that the CH2OS register is inverted. To apply a positive offset, a negative number is written to this register.
0x0F	GAIN	R/W	8	0x0	U	PGA Gain Adjust. This 8-bit register is used to adjust the gain selection for the PGA in Channels 1 and 2—see the Analog Inputs section.
0x10	PHCAL	R/W	6	0x0D	S	Phase Calibration Register. The phase relationship between Channel 1 and 2 can be adjusted by writing to this 6-bit register. The valid content of this two's complement register is between 0x1D to 0x21. At a line frequency of 60 Hz, this is a range from -2.06° to $+0.7^\circ$ —see the Phase Compensation section.
0x11	APOS	R/W	16	0x0	S	Active Power Offset Correction. This 16-bit register allows small offsets in the active power calculation to be removed—see the Active Power Calculation section.

ADE7753

Address	Name	R/W	No. Bits	Default	Type ¹	Description
0x27	PERIOD	R	16	0x0	U	Period of the Channel 2 (Voltage Channel) Input Estimated by Zero-Crossing Processing. The MSB of this register is always zero.
0x28– 0x3C						Reserved.
0x3D	TMODE	R/W	8	–	U	Test Mode Register.
0x3E	CHKSUM	R	6	0x0	U	Checksum Register. This 6-bit read-only register is equal to the sum of all the ones in the previous read—see the ADE7753 Serial Read Operation section.
0x3F	DIEREV	R	8	–	U	Die Revision Register. This 8-bit read-only register contains the revision number of the silicon.

¹Type decoder: U = unsigned, S = signed by two's complement method, and S' = signed by sign magnitude method.

ORDEN DE EMPASTADO