

# Application of a smart electricity meter to improve electricity consumption analysis

Linett Angélica Velasquez Jimenez, Doctor<sup>1</sup>, Eduardo Nelson Chavez Gallegos, Maestro<sup>2</sup>, Angélica Nashara Rubiños Encarnación, Ingeniera<sup>3</sup>, Freddy Adan Castro Salazar, Doctor<sup>2</sup>, Santiago Linder Rubiños Jimenez, Doctor<sup>4</sup>, Juan Jesús Escalante Rosales, Doctor<sup>2</sup>

<sup>1</sup>Universidad de Ciencias y Humanidades, Perú, [lavelasquezj@unac.edu.pe](mailto:lavelasquezj@unac.edu.pe).

<sup>2</sup>Universidad Nacional del Callao, Perú, [enchavezg@unac.edu.pe](mailto:enchavezg@unac.edu.pe), [facastros@unac.edu.pe](mailto:facastros@unac.edu.pe), [jjescalanter@unac.edu.pe](mailto:jjescalanter@unac.edu.pe)

<sup>3</sup>Universidad Cesar Vallejo, Perú, [anrubinose@ucv.edu.pe](mailto:anrubinose@ucv.edu.pe)

<sup>4</sup>Universidad Nacional Tecnológica de Lima Sur, Perú, [slrubinos@untels.edu.pe](mailto:slrubinos@untels.edu.pe)

**Abstract**– This research presents the development and evaluation of a smart electrical meter designed to measure, analyze, and remotely monitor key power-quality parameters using low-cost sensors and an ESP32 microcontroller. The system captures voltage and current through SCT-013-100 and ZMPT101B sensors, processes the data locally, and transmits it via Wi-Fi to a cloud platform, where users can visualize measurements in real time through a mobile application. Machine-learning techniques, including Empirical Mode Decomposition (EMD), Kernel PCA, and Support Vector Machines (SVM), were implemented to extract features and classify electrical consumption patterns. Experimental validation showed high accuracy in voltage readings, with errors near  $\pm 1.10\%$  for low loads and around 0.5% compared to a professional CW500 meter. Current measurements remained acceptable, despite occasional deviations linked to synchronization differences. The system also accurately registered frequency stability at 60 Hz and enabled harmonic-distortion and active-power analysis. Overall, the smart meter demonstrated reliable performance for real-time monitoring and represents a scalable, low-cost solution for energy-quality assessment.

**Keywords**-- Smart meter, EMD, KPCA, SVM.

# Aplicación de un medidor eléctrico inteligente para mejorar el análisis de consumo eléctrico

Linett Angélica Velasquez Jimenez, Doctor<sup>1</sup>, Eduardo Nelson Chavez Gallegos, Maestro<sup>2</sup>, Angélica Nashara Rubiños Encarnación, Ingeniera<sup>3</sup>, Freddy Adan Castro Salazar, Doctor<sup>2</sup>, Santiago Linder Rubiños Jimenez, Doctor<sup>4</sup>, Juan Jesús Escalante Rosales, Doctor<sup>2</sup>

<sup>1</sup>Universidad de Ciencias y Humanidades, Perú, lavelasquezj@unac.edu.pe.

<sup>2</sup>Universidad Nacional del Callao, Perú, enchavezg@unac.edu.pe, facastros@unac.edu.pe, jjescalanter@unac.edu.pe

<sup>3</sup>Universidad Cesar Vallejo, Perú, anrubinose@ucv.edu.pe

<sup>4</sup>Universidad Nacional Tecnológica de Lima Sur, Perú, slrubinos@untels.edu.pe

**Resumen:** Esta investigación presenta el desarrollo y la evaluación de un medidor eléctrico inteligente diseñado para medir, analizar y monitorear de forma remota parámetros clave de la calidad de la energía utilizando sensores de bajo costo y un microcontrolador ESP32. El sistema captura el voltaje y la corriente a través de los sensores SCT-013-100 y ZMPT101B, procesa los datos localmente y los transmite vía Wi-Fi a una plataforma en la nube, donde los usuarios pueden visualizar las mediciones en tiempo real a través de una aplicación móvil. Se implementaron técnicas de aprendizaje automático, incluyendo la Descomposición Empírica de Modos (EMD), el PCA de Kernel y las Máquinas de Vectores de Soporte (SVM), para extraer características y clasificar los patrones de consumo eléctrico. La validación experimental mostró una alta precisión en las lecturas de voltaje, con errores cercanos a  $\pm 1,10$  % para cargas bajas y alrededor del 0,5 % en comparación con un medidor profesional CW500. Las mediciones de corriente se mantuvieron aceptables, a pesar de desviaciones ocasionales relacionadas con diferencias de sincronización. El sistema también registró con precisión la estabilidad de la frecuencia a 60 Hz y permitió el análisis de la distorsión armónica y la potencia activa. En general, el medidor inteligente demostró un rendimiento confiable para el monitoreo en tiempo real y representa una solución escalable y de bajo costo para la evaluación de la calidad de la energía.

**Palabras clave:** Medidor inteligente, EMD, KPCA, SVM.

## I. INTRODUCCIÓN

En sus inicios, los medidores eléctricos tenían como única función registrar el consumo de energía de cada usuario, tarea que se realizaba con medidores electromecánicos simples [1]. Sin embargo, estos dispositivos han evolucionado hacia contadores automáticos e inteligentes, conocidos como Smart Meters, que permiten la recolección de datos de consumo, tanto para la empresa proveedora como para el usuario, y el monitoreo de la calidad de la energía [2]. El concepto de "calidad de la energía" describe las variaciones en el voltaje, la corriente y la frecuencia del sistema eléctrico, que se han

vuelto más notables en los últimos cinco a diez años debido a la incorporación de numerosos equipos y herramientas en procesos de producción y laboratorios, lo que provoca fluctuaciones en las mediciones [3]. Entre estos fenómenos se encuentran caídas y picos de tensión, interrupciones, distorsiones armónicas, fluctuaciones de voltaje, transitorios oscilatorios o impulsivos, ruido, sobrevoltajes y subtensiones [4].

Actualmente, la medición de la energía se realiza a través de sensores especializados de voltaje y corriente, conectados a placas electrónicas programables. Estas placas, mediante un código, realizan cálculos eléctricos y muestran los resultados en pantallas o interfaces para facilitar la visualización y toma de decisiones por parte del usuario [5]. Contar con estos modelos de medidores eléctricos proporciona múltiples beneficios, como la seguridad, ya que permiten cumplir con las normativas sobre calidad energética [6]. En algunos países, se han implementado tecnologías y sistemas para mejorar y supervisar el uso de energía en los hogares [7]. Sin embargo, en América Latina, las redes eléctricas no han tenido mejoras sustanciales. En Perú, el registro de consumo en los medidores eléctricos sigue realizándose de forma manual por empleados de las empresas distribuidoras, quienes recogen los datos personalmente [8]. Si bien esta tecnología ya presenta un desarrollo en el mercado, su implementación en contextos locales aún presenta limitaciones.

Por lo tanto, en esta investigación se implementa un medidor de consumo de energía eléctrica basado en la aplicación del aprendizaje automático con el Support Vector Machine (SVM), lo que permite un monitoreo y análisis más preciso del consumo energético.

## II. MATERIALES Y MÉTODOS

### A) Esquema General

El medidor inteligente contará con el uso del sensor SCT 013-100 para medir la corriente y el sensor ZMPT101B para medir el voltaje, ambos envían su información al ESP32 que realiza el cálculo de las magnitudes y luego envía la información a la base de datos Firebase y también lo muestra en la pantalla LCD. Se podrá acceder a esta información desde

la laptop o el aplicativo del celular que fue realizado con el APP inventor. Todo este esquema se visualiza en la figura 1.




Figura 1. Esquema general del medidor de consumo de energía

#### - Módulo ESP32

El ESP32 es un microcontrolador SoC (sistema en chip) accesible y eficiente en el uso de energía, con conectividad Wi-Fi y Bluetooth integrada. Desarrollado por Espressif Systems, está destinado a una amplia variedad de aplicaciones, tales como dispositivos de Internet de las cosas (IoT), aparatos electrónicos portátiles y otros sistemas embebidos (ver figura 2). Este módulo incluye procesadores de doble núcleo que pueden operar hasta 240 MHz. También es compatible con diversos protocolos de comunicación, entre ellos Wi-Fi, Bluetooth y Ethernet. [9].



Figura 2. Esp32 Module

#### - Pantalla LCD TFT de 2,4"

El controlador LCD ILI9341 cuenta con una resolución de 320×240 píxeles y una gama de 262,000 colores. Incluye un panel táctil resistivo de 4 hilos y es compatible con una tensión de 5V. Sus dimensiones son de 71 x 52 x 7 mm (largo, ancho y alto). Para este proyecto, se eligió una pantalla LCD TFT de 2.4" con interfaz de comunicación SPI y funcionalidad táctil (ver Figura 3), la cual ofrece una mayor nitidez y diversidad de colores, además de permitir la interacción del usuario.



Figura 3. Pantalla TFT 2.4"

#### - Sensor de corriente SCT 013-100

Se escogió un TC de núcleo partido modelo SCT 013-100, tiene la relación de transformación de 100 amperios en el lado del primario a 50 miliamperios DC en el lado del secundario (ver figura 4). Se escogió debido a su bajo costo, fácil instalación para la medición de corriente y el rango de mediciones, lo cual lo vuelve viable para el equipo de medición.



Figura 4. Transformador de Corriente SCT 013-100

#### - Sensor de voltaje ZMPT101B.

El sensor ZMPT101B es un módulo empleado para medir el voltaje de fase en corriente alterna (ver figura 5). Este módulo, que incluye un transformador de voltaje, está diseñado específicamente para detectar voltaje alterno. Cuenta con una salida activa monofásica y un circuito con amplificador operacional que ajusta el offset de la señal analógica de salida. Es capaz de medir voltajes de baja tensión, siendo adecuado para valores como 220 V, y dispone de un potenciómetro de 0 a 10 kΩ en la placa para regular la amplitud de la señal de salida. Este módulo resulta ideal para aplicaciones de monitoreo y protección de equipos de corriente alterna [10].



Figura 5. Sensor de voltaje ZMPT101B

#### - Relés de Estado Sólido

Un relé de estado sólido es un dispositivo de conmutación eléctrica que se activa o desactiva al suministrar una pequeña tensión externa a sus terminales de control (Ver figura 6). A diferencia de los relés

electromecánicos (EMR), que funcionan y conmutan una fuente de alimentación mediante bobinas, campos magnéticos, resortes y contactos mecánicos, el SSR no incorpora bobinas ni piezas móviles. Como EMR, el SSR ofrece un aislamiento eléctrico completo entre sus contactos de entrada y salida. Además, las corrientes CC, CA monofásica y trifásica se conmutan fácilmente mediante los SSR adecuados. Generalmente, el SSR empleaba triacs o transistores de conmutación, además de un circuito de control de baja tensión.



Figura 6. Relé de estado sólido

#### - FIREBASE

Firebase puede ser considerada como una plataforma de aplicación web, es muy utilizada por desarrolladores para la creación de aplicaciones móviles (ver figura 7). La información es almacenada en formato JSON (notación de objeto de JavaScript) y es una base de datos NoSQL. Los servicios disponibles de Firebase son: Firebase Analytics, Real-time Database, Storage, etc.



Figura 7. Funcionalidades del Firebase

La base de datos en tiempo real de Firebase permite crear aplicaciones que permitan una conexión segura desde el lado del cliente hasta el transporte de los datos. Los datos continúan almacenados en caché localmente en el servidor. Además, esta base de datos ofrece un lenguaje de reglas adaptable basado en expresiones, llamado Firebase Realtime Database Security Rules, para establecer cómo deben permanecer organizados y cuando se pueden sobrescribir los datos. Esta base de datos soporta dispositivos Android, iOS, aplicaciones web y más. Todos los datos manejados en esta base de datos están en formato JSON (JavaScript Object Notation), y cualquier cambio es

reflejado inmediatamente pues se realiza una sincronización en todas las plataformas conectadas [11]. Esto ayuda a desarrollar aplicaciones que requieran sincronizar datos en tiempo real sin mayor esfuerzo, aun si el usuario final está desconectado de internet, y una vez que se detecta que el dispositivo se ha conectado, se le transfiere los datos almacenados hacia el usuario [12].

#### B) Clasificación de Consumo Eléctrico basado en EMD, KPCA y SVM a partir de Datos de un Medidor Eléctrico Inteligente

##### - Algoritmo EMD

Dada una señal  $S_1(t)$ , el punto de partida de EMD es la identificación de todos los máximos y mínimos locales. Entonces, todos los máximos locales están conectados por una curva spline cúbica que actúa como envolvente superior  $e_u(t)$ ; de manera similar, todos los mínimos locales están conectados por una curva spline que actúa como envolvente inferior  $e_l(t)$  [13]. La media de las dos envolventes se denota por  $m_1(t) = [e_u(t) + e_l(t)]/2$  y se resta de la señal. Por lo tanto, el primer proto-IMF  $h_1(t)$  se obtiene de la siguiente manera:

$$h_1(t) = x(t) - m_1(t)$$

Luego se examina si  $h_1(t)$  cumple la condición de componente de modo intrínseco. De no ser así, repita la operación anterior hasta que  $h_1(t)$  sea un componente de modo intrínseco [14], y se denote como:

$$c_1(t) = h_1(t)$$

Luego, considerando  $r_1(t)$  como una señal bruta similar a  $x(t)$ , y la segunda, la tercera hasta la FMI de orden  $n$ , se pueden calcular repitiendo los pasos anteriores, que se pueden representar como  $c_2(t)$ ,  $c_3(t)$ , ...,  $c_n(t)$ . El proceso iterativo no finalizará hasta que se cumpla algún criterio, y la última señal residual sea  $r_n(t)$  que es una función monótona de la que no se pueden extraer más FMI. Por lo tanto, la señal bruta primaria  $x(t)$  se puede descomponer en un conjunto de FMI y una señal residual [15], que se muestra como:

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t)$$

Con el aumento de los tiempos de cribado, el valor medio de la envolvente se acercará cada vez más a cero y el error se amplificará gradualmente, haciendo que la señal original pierda relevancia práctica. Por lo tanto, se selecciona la desviación estándar (SD) de dos componentes residuales continuos como condición de terminación:

$$SD = \sum_{t=0}^T \frac{|h_{k-1}(t) - h_k(t)|^2}{|h_{k-1}(t)|^2}$$

donde  $T$  es el lapso de tiempo de la señal,  $h_{k-1}(t)$  y  $h_k(t)$  son dos secuencias consecutivas en el proceso de cribado de componentes de modo intrínseco (Ver figura 8), y el valor de  $SD$  suele controlarse dentro del rango de [0.2, 0.3], lo que puede garantizar que el componente tenga importancia física y evitar la interferencia causada por una descomposición excesiva. Se adoptó el método de relación de energía para extraer el IMF, luego el componente de señal se extrajo mediante EMD [16].




Figura 8. Proceso de descomposición de EMD Extracción de características

El EMD descompone la señal en un conjunto de FMI, cada una de las cuales incluye la característica local de la señal. Dado que el WT opera con diferentes fallas, la energía de amplitud de cada FMI es diferente; por lo tanto, se adopta como vector de entrada de un clasificador. Si la señal se descompone en  $n$  FMI y un residuo  $m(t)$ , la entropía energética de cada  $E_i$  de las primeras  $m$  FMI se calcula como:

$$E_i = \sum_{k=1}^M |c_i(k)|^2$$

donde  $n$  es la longitud de datos discretos del  $i$ -ésimo FMI. La energía total de algunas FMI puede ser muy grande, por lo tanto, el vector propio se normaliza como:

$$T = \begin{bmatrix} \frac{E_1}{E} & \frac{E_2}{E} & \dots & \frac{E_n}{E} \end{bmatrix}$$

Donde

$$E = \sum_{i=1}^n E_i$$

El vector propio normalizado  $T$  es un buen indicador para la detección de fallos. La porción energética de cada FMI se observa en la siguiente ecuación:

$$p_i(t) = \frac{E_i(t)}{\sum_{i=1}^n E_i(t)} \quad (i = 1, 2, \dots, n)$$

Donde  $p_i$  es el porcentaje de la energía de  $h(t)$  en la energía total de la señal. La entropía energética del FMI se define como:

$$H = - \sum_{i=1}^n p_i \log p_i$$

Por lo tanto, la media de entropía energética de las IMF podría utilizarse como vectores de características de falla [17]. Tras extraer un vector de características de falla, se podría elegir el SVM como clasificador para identificar la condición de trabajo y el patrón de falla. Los métodos EMD y SVM para el diagnóstico de fallas se pueden resumir de la siguiente manera:

1) Muestrear  $N$  veces a una frecuencia de muestreo  $f_s$  determinada, con la condición de que se considere cada posible falla. Las muestras, que se dividen en dos subconjuntos: muestras de entrenamiento y muestras de prueba.

2) Cada señal de muestra se descompone mediante el método EMD y se calcula la media de entropía de energía de cada IMF para construir un vector de características inicial.

3) La velocidad del motor (RPM) de cada muestra se normaliza para construir otro vector de características inicial.

Diseñar un clasificador SVM. La media de entropía de energía y las RPM de normalización del vector de características inicial de las muestras de entrenamiento se utilizan como vectores de características de falla que se utilizarán como entrada para los clasificadores SVM, que se entrenan [18].

#### - Kernel PCA

Kernel PCA es una generalización no lineal de PCA que emplea el truco del kernel. El concepto básico de kernel PCA es expandir las características mediante transformaciones no lineales en un espacio de características de alta dimensión  $\phi(x_n)$  ( $\phi \in \mathbb{R}^L$ ) y luego aplicar PCA en el nuevo espacio de características. Por lo tanto, un PCA lineal en  $\phi(x_n)$  corresponde a un PCA no lineal en el espacio de datos original  $x_n$  porque  $x_n$  se reemplaza por  $\phi(x_n)$  [19]. El principio básico del algoritmo de componentes principales del kernel (KPCA) es: los

datos originales de baja dimensión se transforman de forma no lineal utilizando una función no lineal, y los datos transformados se proyectan en un espacio de características de alta dimensión F, y un algoritmo para el análisis de componentes principales en el espacio F.

$XL' \times n$  es el conjunto de entrenamiento con  $l'$  variables móviles y  $n$  muestras,  $x_i \in R^{l'}$  ( $i = 1, 2, \dots, n$ ). Entonces, la matriz de covarianza en el espacio F es:

$$C = \frac{1}{n} \sum_{i=1}^n \phi(x_i) \phi(x_i)^T$$

La ecuación característica correspondiente es:

$$\lambda_i u_i = C u_i$$

En la fórmula,  $\lambda_i$  es el  $i$ -ésimo valor propio de la matriz de covarianza C, y  $u_i$  es el vector propio correspondiente a  $\lambda_i$  [11].

Los autovalores y los autovectores correspondientes de la matriz C son  $\lambda = [\lambda_1, \lambda_2, \dots, \lambda_k]$ , y  $U = [u_1, u_2, \dots, u_k]$ . Para seleccionar el número k, se introduce un umbral  $\theta$  para denotar la precisión de aproximación de los k vectores propios más grandes. El autovector correspondiente al autovalor con la mayor magnitud tiene la mayor contribución a la información original principal, y viceversa. Por lo tanto, el autovector correspondiente al autovalor con la magnitud pequeña puede ser insignificante. Los primeros k autovalores grandes se conocen como los primeros k componentes principales (CP). La tasa de contribución acumulada se define como

Para mantener una información original adecuada, en términos generales, P debe satisfacer ciertos requisitos.

$$P = \sum_{i=1}^k \lambda_i / \sum_{i=1}^d \lambda_i \geq \theta$$

#### - Máquinas de Vectores de Soporte (Svm)

El uso de redes neuronales artificiales para la clasificación tiene varias desventajas. Como primera desventaja, la función de error es multimodal, lo que incluye muchos mínimos locales. Por tanto, el proceso de aprendizaje de este clasificador puede enfrentar problemas. Además, requieren una gran cantidad de datos para su entrenamiento. SVM es otro clasificador que se usa ampliamente porque no tiene las desventajas anteriores. SVM utiliza un algoritmo particular para maximizar el margen de separación entre 2 clases. Dado que el entrenamiento de SVM busca una solución global optimizada y evita el sobreajuste, tiene la capacidad de manejar un gran número de características [20]. En el proceso de entrenamiento, se proporciona un conjunto de pares de datos al SVM.

$$(x_i, y_i), \text{ para } i = 1, 2, 3, \dots, m$$

donde,  $x_i \in R_m$ ,  $y_i \in (1, -1)$ , el hiperplano de separación se da por

$$W^T \cdot x + b = 0$$

Donde el vector w (un vector normal al hiperplano) define el límite, x es el vector de entrada de dimensión, y es la etiqueta de la falla N, y b es un umbral escalar. En el caso de separabilidad lineal, los puntos de datos se clasifican por

$$w \cdot x + b \geq 1 \text{ para todo } y_i = 1$$

$$w \cdot x + b \leq -1 \text{ para todo } y_i = -1$$

Sus valores deben derivarse de tal manera que los datos desconocidos se clasifiquen con precisión. Esto es posible maximizando el margen de separación entre las clases, que se define como se muestra en:

$$m = \frac{2}{\|W\|}$$

Para maximizar m, W debe minimizarse. Para un conjunto dado de datos linealmente separables, esto puede formularse como un problema de optimización cuadrática, como se muestra en:

$$\min \frac{1}{2} \|W\|^2$$

Sujeta a,

$$y_i(w \cdot x_i + b) \geq 1, i = 1, 2, \dots, n$$

Al restringir la norma euclidiana de w,  $\|w\|$ , al mínimo, el método SVM busca encontrar un hiperplano separador único [21]. En este caso, la distancia entre el hiperplano y los puntos de datos más cercanos de cada clase es  $\frac{2}{\|W\|}$




Figura 9. Gráfico SVM

Este problema es muy difícil de resolver directamente debido a la complejidad de las restricciones. Por lo tanto, se

utiliza la teoría de la dualidad lagrangiana para simplificarlo. La introducción de multiplicadores de Lagrange en el problema de optimización permite resolver el siguiente problema dual.

$$Max\{D(\alpha)\} = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m \{y_i \alpha_i y_j \alpha_j \phi(x_i)^T \phi(x_j)\}$$

con,

$$\sum_{i=1}^m y_i \alpha_i = 0 \text{ y } \alpha_i \geq 0, i = 1, 2, \dots, m$$

Este problema dual es computacionalmente más sencillo porque sus restricciones son mucho más simples. La solución  $\alpha^*$  del problema de optimización dual (es decir, la ecuación 21) recupera la dirección  $w^*$  del hiperplano óptimo.

$$w^* = \sum_{i=1}^m \alpha_i^* y_i \phi(x_i)$$

Determinar el sesgo  $b^*$  se convierte en un problema unidimensional simple. La función discriminante lineal puede entonces escribirse como:

$$\hat{y}(x) = w^{*T}x + b^* = \sum_{i=1}^m \{y_i \alpha_i^* \phi(x_i)^T \phi(x)\} + b^*$$

Este problema puede resolver un caso lineal, pero en otros casos donde el límite lineal no es suficiente para separar adecuadamente dos clases diferentes en espacios de entrada, es decir, la clasificación no lineal, se requiere el mapeo SVM para mapear el vector de entrada N-dimensional a un espacio de características de mayor dimensión [22]. El problema de optimización lineal y la función discriminante lineal solo asocian patrones  $x$  mediante el cálculo del producto escalar en el espacio de características. Si se puede calcular el producto escalar directamente, no es necesario calcular la función de características,  $\phi(x)$ . En lugar de elegir,  $\phi(x)$ , introdujeron la selección directa de una función kernel  $k(x, x')$  que sustituye un producto escalar  $\phi(x)^T \phi(x')$  en un espacio de alta dimensión indefinido. Entonces, la forma básica de SVM será:

$$\hat{y}(x) = \sum_{i=1}^m \{y_i \alpha_i K(x, x_i)\} + b$$

donde  $b$  es el sesgo,  $y$  es la salida,  $\alpha$  el multiplicador de Lagrange y  $l$  es el tamaño del conjunto de entrenamiento. La formulación anterior de SVM se basa en la clasificación binaria y puede gestionar el caso multiclase simplemente combinándola [23].

### C) Diseño e Implementación del Tablero

La arquitectura propuesta del tablero de distribución incluye interruptores automáticos (CB), relés de estado sólido (RES), una caja de conexiones, sensores de tensión y corriente, una fuente de alimentación de CC y un microcontrolador equipado con un módulo WiFi, como se ilustra en la Figura 10. Para medir la potencia y el consumo de energía, los sensores del nodo terminal recopilan las señales de tensión y corriente. El microcontrolador ofrece computación en el borde de diversas magnitudes eléctricas, como los valores de tensión y corriente de línea en valores RMS (valor eficaz). Las mediciones recopiladas y los datos calculados se envían a la plataforma IoT a través de una puerta de enlace o punto de acceso mediante el enlace de comunicación WiFi y los protocolos IoT. Además de la visualización interactiva de los datos transmitidos, la plataforma IoT utilizada ofrece la capacidad de computación en la nube para analizar los datos recibidos y permitir que las instalaciones tomen las medidas necesarias.




Figura 10. Implementación del tablero de distribución.

### III. RESULTADOS

Con base en la metodología detallada, las mediciones tomadas con el prototipo de medidor inteligente se transmitieron mediante Wi-Fi desde el ESP32 a la plataforma virtual. En esta plataforma se visualiza, guarda el registro de mediciones eléctricas, analiza en tiempo real e ilustra los diferentes parámetros eléctricos como tensión y corriente, ilustrados en la figura 11 y 12 respectivamente.



Figura 11. Análisis de tensión



Figura 12. Análisis de corriente

La contrastación entre el módulo desarrollado con respecto al instrumento de medición dio como resultado un error de medición bastante aceptable con:  $\pm 1.10\%$  para cargas menores a los 7 amperios y con cargas superiores a este valor se obtuvo un rango de error del  $\pm 3.04\%$  de acuerdo como se muestra en la Tabla 1.

TABLA I  
Error de medición de voltaje y corriente para diferentes muestras

| Tensión (FLUKE) | Corriente (FLUKE) | Tensión (MÓDULO) | Corriente (MÓDULO) | % error (Tensión) | % error (Corriente) |
|-----------------|-------------------|------------------|--------------------|-------------------|---------------------|
| 239.22          | 1.13              | 240.21           | 1.12               | 0.791             | -0.885              |
| 239.34          | 1.03              | 240.46           | 1.02               | 0.894             | -0.971              |
| 236.81          | 7.37              | 237.18           | 7.28               | 0.301             | -1.221              |
| 239.23          | 7.82              | 239.12           | 7.71               | -0.089            | -1.407              |
| 236.84          | 9.73              | 236.6            | 9.4                | -0.195            | -2.098              |
| 237.43          | 11.47             | 236.34           | 11.11              | -1.045            | -2.327              |
| 236.78          | 15.46             | 236.44           | 15.06              | -0.277            | -2.587              |
| 239.18          | 15.61             | 239.73           | 15.03              | -0.365            | -3.716              |
| 237.59          | 15.73             | 237.83           | 15.21              | 1.003             | -3.306              |
| 237.15          | 16.94             | 237.98           | 16.22              | 1.486             | -4.25               |

Para examinar el desempeño y efectúa el medidor inteligente y con ello establecer su pertenencia, se efectuó una comparación con el equipo CW500. Dicho estudio consistió en contrastar las mediciones de voltaje y corriente registradas en distintos intervalos temporales, incluyendo una evaluación específica basada en datos recopilados a lo largo de la jornada completa.




Figura 13. Análisis comparativo de un día entre CW500 y un medidor inteligente

Con base en la figura 13 se aprecia que los voltajes presentaron un desempeño sobresaliente, pues las mediciones realizadas por el medidor inteligente muestran una gran similitud con las obtenidas por el CW500. En el caso de los voltajes, los errores relativos resultaron cercanos al 0.5%, exceptuando algunos valores atípicos. No obstante, al evaluar los errores relativos correspondientes a la corriente, se observaron valores que superaron el 8%, con una frecuencia aproximada cercana al 2.8%. Asimismo, se detectaron discontinuidades en los valores registrados por el medidor inteligente, debido a la falta de sincronización precisa entre este dispositivo y el medidor CW500. Este factor generó una tasa de error relativamente alta.

### Resultados de potencia, factor de potencia, frecuencia y armónicos en pruebas de campo

En la Figura 14, se observa que la frecuencia se mantuvo en 60 Hz, donde se realizaron todas las pruebas de campo. En los cálculos de error relativo, la tasa de error fue del 0 %, salvo por valores atípicos que surgieron debido a problemas de conexión durante la adquisición de datos.



Figura 14. Serie temporal de frecuencias medidas a lo largo de un día.

Con base en los datos de frecuencia, voltaje y corriente recopilados (como se muestra arriba), fue posible determinar las tasas de distorsión armónica total, como se ilustra en la Figura 15. Además, se realizaron mediciones de la potencia activa, que se representan en la Figura 16.




Figura 15. Serie temporal de distorsiones armónicas totales de voltajes durante el transcurso de un día




Figura 16. Serie temporal de potencia activa a lo largo de un solo día

## V. CONCLUSIONES

A partir de los resultados experimentales obtenidos, se determinó que el prototipo de medidor inteligente es capaz de registrar y transmitir parámetros eléctricos básicos (tensión, corriente y frecuencia) mediante comunicación Wi-Fi hacia la plataforma Ubidots, evidenciando su funcionalidad para aplicaciones de monitoreo remoto. En la medición de tensión, se obtuvieron errores relativos de aproximadamente  $\pm 1.10\%$  en condiciones de baja carga y cercanos al  $0.5\%$  al compararse con el equipo de referencia CW500. Estos valores se encuentran dentro de rangos aceptables para sistemas de monitoreo no certificado, lo que indica un adecuado nivel de precisión en esta variable. Respecto a la medición de corriente, los errores relativos se mantuvieron alrededor de  $\pm 1.10\%$  para corrientes menores a 7 A y alcanzaron valores de hasta  $3.04\%$  en corrientes mayores. Asimismo, se observó que menos del  $3\%$  de las mediciones presentaron errores superiores al  $8\%$ , lo cual se atribuye principalmente a la falta de sincronización temporal entre el prototipo y el equipo de referencia, constituyendo una fuente identificada de incertidumbre en las mediciones. En cuanto a la frecuencia, se registró un valor constante de 60 Hz con un error relativo de  $0\%$ , lo que indica estabilidad en su medición bajo las condiciones evaluadas. Adicionalmente, el sistema permitió el cálculo de potencia activa y distorsión armónica, lo cual amplía su funcionalidad hacia el análisis de calidad de energía. Sin embargo, la precisión de estos parámetros depende de la exactitud en la adquisición de las variables primarias. En conjunto, los resultados evidencian que el prototipo presenta un desempeño adecuado para aplicaciones de monitoreo en tiempo real, dentro de márgenes de error conocidos y cuantificados.

## AGRADECIMIENTO

Agradecemos a la Universidad Nacional del Callao y al Vicerrectorado de Investigación, en virtud de las lecciones aprendidas y las valiosas sugerencias y recomendaciones que nos ha proporcionado

## REFERENCIAS

- [1] Z. Zhang, "Research on the evolution of smart meter technology," ArXiv, vol. abs/2403.15406, doi: 10.48550/ARXIV.2403.15406.
- [2] Y. M. Rind, M. H. Raza, M. Zubair, M. Q. Mehmood, and Y. Massoud, "Smart Energy Meters for Smart Grids, an Internet of Things Perspective," *Energies (Basel)*, vol. 16, no. 4, Feb. 2023, doi: 10.3390/EN16041974.
- [3] A. Zambrano, "Procedimiento para la Evaluación de la Calidad de la Energía en Industrias con Cargas Eléctricas Variables no Lineales," Universidad de las Fuerzas Armadas, 2022.
- [4] A. Outman *et al.*, "Obtaining of New Antioxidant and Antimicrobial Peptides Derived from Human Hemoglobin by Peptide Hydrolysis and Comparison with These Obtained by Bovine Hemoglobin," *MDPI*, 2023, doi: 10.20944/preprints202307.
- [5] K. Buenaventura and W. Villamar, "Sistema de monitoreo de consumo de energía eléctrica en tiempo real de bajo costo basado en internet de las cosas," ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL, 2022.
- [6] A. Yumenchuk, "Review of Modern Electricity Metering Devices," *System Analysis & Mathematical Modeling*, vol. 4, no. 1, pp. 38–45, Apr. 2022, doi: 10.17150/2713-1734.2022.4(1).38-45.
- [7] F. M. Dahunsi, O. R. Olakunle, and A. O. Melodi, "Evolution of Electricity Metering Technologies in Nigeria," *Nigerian Journal of Technological Development*, vol. 18, no. 2, pp. 152–165, Jul. 2021, doi: 10.4314/NJTD.V18I2.10.
- [8] M. Velásquez, "DISEÑO E IMPLEMENTACIÓN DE UN PROTOTIPO DE SISTEMA TELEMÉTRICO BASADO EN IoT PARA REDUCIR EL TIEMPO DEL REGISTRO DEL CONSUMO DE LA ENERGÍA ELÉCTRICA MONOFÁSICA RESIDENCIAL UTILIZANDO TECNOLOGÍA LPWAN," UNIVERSIDAD RICARDO PALMA, 2021.
- [9] S. Takreem and K. Asadulla, "IoT- Based Smart Metering Mirror System for Monitoring Electric Bills during Pandemic," 2021.
- [10] R. Reyes, "DISEÑO E IMPLEMENTACIÓN DE UN SISTEMA DE ADQUISICIÓN DE PARAMETROS DE UN MOTOR DE INDUCCIÓN," INSTITUTO TECNOLÓGICO DE CIUDAD MADERO, 2018.
- [11] J. Salazar, "Propuesta de sistema de lectura remota de medidores de energía eléctrica, para mejorar la eficiencia del Servicio Ensa – Lambayeque," UNIVERSIDAD NACIONAL "PEDRO RUIZ GALLO," 2022.
- [12] Caceres Edinson, "Desarrollo de una plataforma basada en Telemetría e IoT para el monitoreo remoto del consumo e indicadores de de energía de una planta real," Universidad Politecnica Salesiana Ecuador, 2019.
- [13] D. Yang, H. Li, Y. Hu, J. Zhao, H. Xiao, and Y. Lan, "Vibration condition monitoring system for wind turbine bearings based on noise suppression with multi-point data fusion," *Renew Energy*, vol. 92, pp. 104–116, Jul. 2016, doi: 10.1016/j.renene.2016.01.099.
- [14] Q. Yang and D. An, "EMD and wavelet transform based fault diagnosis for wind turbine gear box," *Advances in Mechanical Engineering*, vol. 2013, 2013, doi: 10.1155/2013/212836.
- [15] W. Teng, F. Wang, K. Zhang, Y. Liu, and X. Ding, "Pitting fault detection of a wind turbine gearbox using empirical

- mode decomposition,” *Strojnicki Vestnik/Journal of Mechanical Engineering*, vol. 60, no. 1, pp. 12–20, 2014, doi: 10.5545/sv-jme.2013.1295.
- [16] L. Cao and W. Sun, “Development of gear fault identification of wind turbine’s transmission system based on VMD and FNN,” *Vibroengineering Procedia*, vol. 55, pp. 60–66, Sep. 2024, doi: 10.21595/vp.2024.24329.
- [17] Y. Wang, W. Sun, L. Liu, B. Wang, S. Bao, and R. Jiang, “Fault Diagnosis of Wind Turbine Planetary Gear Based on a Digital Twin,” *Applied Sciences (Switzerland)*, vol. 13, no. 8, Apr. 2023, doi: 10.3390/app13084776.
- [18] Du Wei and Liu Quan, “A New Ball Bearing Fault Diagnosis Method Based on EMD and SVM,” *Advanced Electrical and Electronics Engineering*, vol. 87, pp. 423–428, 2011.
- [19] P. Korkos, J. Kleemola, M. Linjama, and A. Lehtovaara, “Representation Learning for Detecting the Faults in a Wind Turbine Hydraulic Pitch System Using Deep Learning,” *Energies (Basel)*, vol. 15, no. 24, Dec. 2022, doi: 10.3390/en15249279.
- [20] A. Foroughi, E. Mohammadi, and S. Esmacili, “Application of Hilbert{Huang transform and support vector machine for detection and classification of voltage sag sources,” *Turkish Journal of Electrical Engineering and Computer Sciences*, vol. 22, no. 5, pp. 1116–1129, 2014, doi: 10.3906/elk-1210-60.
- [21] P. Gangsar and R. Tiwari, “ANALYSIS OF TIME, FREQUENCY AND WAVELET BASED FEATURES OF VIBRATION AND CURRENT SIGNALS FOR FAULT DIAGNOSIS OF INDUCTION MOTORS USING SVM,” *Proceedings of the ASME 2017 Gas Turbine India Conference*, Dec. 2017, [Online]. Available: <http://www.asme.org/about-asme/terms-of-use>
- [22] N. Ramesh Babu and B. Jagan Mohan, “Fault classification in power systems using EMD and SVM,” *Ain Shams Engineering Journal*, vol. 8, no. 2, pp. 103–111, Jun. 2017, doi: 10.1016/j.asej.2015.08.005.
- [23] P. Gangsar and R. Tiwari, “Taxonomy of Induction-Motor Mechanical-Fault Based on Time-Domain Vibration Signals by Multiclass SVM Classifiers,” *Intelligent Industrial Systems*, vol. 2, no. 3, pp. 269–281, Sep. 2016, doi: 10.1007/s40903-016-0053-x. plataforma APP inventor para monitoreo remoto de sus variables energéticas y control de energéticas y control de encendido aplicado al laboratorio de audiovisual de la esc,” *Universidad Politecnica Salesiana Sede Guayaquil*, 2018.