

SISTEMA INTELIGENTE PARA LA LECTURA DEL CONSUMO DE ENERGÍA ELÉCTRICA MEDIANTE VISIÓN ARTIFICIAL Y COMUNICACIÓN GSM

Vicente Paul Astudillo Cortez
paul.astudillo@ister.edu.ec
ORCID: <https://orcid.org/0000-0002-4125-2349>
Instituto Superior Universitario Rumiñahui - Ecuador

Diego Fernando Pichoasamin Morales
diego.pichoasamin@ister.edu.ec
ORCID: <https://orcid.org/0000-0002-8961-6295>
Instituto Superior Universitario Rumiñahui - Ecuador

William Germánico Yugcha Quinatoa
william.yugcha@ister.edu.ec
ORCID: <https://orcid.org/0000-0002-6874-2735>
Instituto Superior Universitario Rumiñahui - Ecuador

Joffre Adalberto Moreira Bermeo
joffre.moreira@ister.edu.ec
ORCID: <https://orcid.org/0009-0007-1402-984X>
Instituto Superior Universitario Rumiñahui - Ecuador

Recibido: 22/05/24

Aceptado: 17/06/24

Publicado: 01/07/24

RESUMEN

En este estudio, se presenta un prototipo de un sistema inteligente para la lectura automatizada del consumo de energía eléctrica en medidores digitales. El sistema, basado en técnicas de visión artificial y comunicación GSM, elimina la necesidad que el personal visite físicamente zonas de difícil acceso para la toma de lecturas manuales. El sistema funciona mediante una cámara acoplada al medidor que captura imágenes del *display*, procesadas en un controlador *Raspberry Pi 4* utilizando la arquitectura *MobileNetV2* y *TensorFlow Lite*. El modelo entrenado logra una precisión del 95% y una sensibilidad del 93% en la detección y reconocimiento de dígitos, demostrando su eficacia y robustez. La implementación del sistema valida su capacidad para adaptarse a diferentes condiciones de iluminación, manteniendo una alta precisión en la lectura de los medidores eléctricos. Esta tecnología innovadora ofrece una solución viable para la automatización de la lectura de medidores, optimizando los procesos de gestión energética y reduciendo costos operativos en zonas de difícil acceso.

PALABRAS CLAVE: visión artificial, internet de las cosas, medición energética, *tensorflow lite*, comunicación GSM.

SMART SYSTEM FOR READING ELECTRICITY CONSUMPTION USING COMPUTER VISION AND GSM COMMUNICATION

ABSTRACT

In this study, a prototype of an intelligent system for the automated reading of electricity consumption in digital meters is presented. The system, based on computer vision and GSM communication techniques, eliminates the need for personnel to physically visit areas of difficult access to take manual readings. The system works by means of a camera attached to the meter that captures images of the display, which are processed in a Raspberry Pi 4 controller using the MobileNetV2 and TensorFlow Lite architecture. The trained model achieves an accuracy of 95% and a sensitivity of 93% in the detection and recognition of digits, demonstrating its effectiveness and robustness. The implementation of the system validates its ability to adapt to different lighting conditions, maintaining high accuracy in the reading of electricity meters. This innovative technology offers a viable solution for the automation of meter reading, optimizing energy management processes and reducing operating costs in areas of difficult access.

KEY WORDS: artificial vision, internet of things, energy measurement, tensorflow lite, GSM communication.

1. INTRODUCCIÓN

A nivel mundial el monitoreo del consumo de energía eléctrica ha sido objeto de diversos estudios, que buscan optimizar y modernizar este proceso mediante el uso de tecnologías emergentes como el internet de las cosas (IOT) (Villao, 2023) (Jimenez, Pablo, Cabrera, 2020), para reducir la interferencia humana en la recopilación de lecturas mensuales de consumo y minimizar los problemas técnicos relacionados y asociados al proceso de facturación. Estas soluciones se basan en el uso de microcontrolador Arduino NodeMCU (esp8266) y un módulo GSM. Este enfoque, no solo promete una mayor fiabilidad en la gestión del consumo energético, sino que también representa un paso significativo hacia la implementación de redes eléctricas inteligentes.

Cabe destacar que la medición del consumo de energía eléctrica es vital en la gestión energética, tanto a nivel doméstico como industrial. Sin embargo, los métodos convencionales de medición pueden ser costosos, imprecisos y propensos a errores humanos (Cáceres Espinoza et al., 2022) (Sandoya, 2021). Por ello, surge la necesidad de desarrollar sistemas inteligentes que permitan una medición más exacta y automatizada. Uno de los principales desafíos es una exhaustiva revisión de las publicaciones del estado del arte, en cuanto a la aplicación de la visión artificial en la medición del consumo de energía eléctrica (Obando, 2022) (Andino, 2023). Se destacan los avances previos en técnicas de procesamiento de imágenes y aprendizaje automático para detectar y rastrear dispositivos eléctricos y para estimar el consumo energético (Torres et al., 2021).

Según los autores Shan et al. (2023), en su estudio de la gestión energética sostenible mediante IoT, monitorea mediante de forma remota la cantidad de energía que se suministra al consumidor empleando un controlador y la red GSM, evitando las lecturas manuales y laboriosas de los medidores.

La arquitectura de control utilizada es *TensorFlow*, una plataforma de aprendizaje automático que opera eficientemente en entornos amplios y heterogéneos. *TensorFlow* emplea gráficos de flujo de datos para representar cálculos, estados compartidos y acciones que modifican dichos estados (Hernández-Molina et al., 2020). Este asigna nodos de gráficos de flujo de datos a muchas máquinas, el uso denominado unidades de procesamiento tensorial (TPU). *TensorFlow* permite a los desarrolladores experimentar con nuevos algoritmos de optimización y entrenamiento, admite una variedad de aplicaciones, especialmente que brinda un fuerte soporte para el entrenamiento e inferencia de redes neuronales profundas. El modelo de flujo de datos de *TensorFlow* en comparación con los sistemas existentes y demuestra el rendimiento convincente de *TensorFlow* en varias aplicaciones del mundo real (Ferdin, John, Sarayut, Nonsiri, Annap, 2021).

El modo operativo de *TensorFlow* es fundamental para el análisis de imágenes capturadas por cámaras instaladas en puntos estratégicos de un entorno eléctrico, así como en el procesamiento de estas imágenes mediante algoritmos de visión artificial. Este método ha sido elegido por su capacidad para proporcionar

mediciones precisas y en tiempo real, además de su versatilidad para adaptarse a diferentes contextos y configuraciones eléctricas (Mejía, 2021) (López, 2020).

El modo operativo de *TensorFlow* permite evaluar la eficacia del sistema propuesto para la medición del consumo de energía eléctrica. Este sistema inteligente se basa en el Internet de las Cosas (IoT), para obtener mediciones precisas de energía eléctrica. El método se define por la configuración de los elementos que componen el GSM y sus respectivos protocolos de comunicación (Chávez et al., 2020) (Ortiz, 2023). El módulo central del sistema es una tarjeta de desarrollo *Raspberry Pi*, que facilita la conectividad IoT y proporciona una solución innovadora para la monitorización y gestión del consumo eléctrico en tiempo real (Pérez, 2023).

El sistema desarrollado se enfoca en dar respuesta a la gestión eficiente del consumo de energía eléctrica, en el contexto actual de creciente demanda energética. Los sistemas inteligentes basados en visión artificial y comunicación GSM para la lectura de medidores eléctricos permite obtener datos precisos y en tiempo real, mejorando la eficiencia y reduciendo costos operativos del sector eléctrico (Coronel, 2020).

El presente trabajo describe el diseño e implementación de un sistema inteligente para la medición del consumo de energía eléctrica mediante visión artificial y comunicación GSM. Este sistema representa una herramienta prometedora para mejorar la eficiencia en la gestión energética. El objetivo es demostrar que esta tecnología tiene el potencial de revolucionar la forma en que se realizan la medición y el monitoreo del consumo eléctrico, contribuyendo así a la reducción de costos y al uso más sostenible de los recursos energéticos (Andrade et al., 2022) (Cepeda et al., 2023).

2. ESTRATEGIAS METODOLÓGICAS / MATERIALES Y MÉTODOS

La metodología de trabajo incluye la descripción de los procesos para el diseño e implementación de un sistema de medición del consumo de energía eléctrica en medidores digitales. Se ejecuta un exhaustivo análisis de la literatura científica en bases de datos especializadas, con el fin de identificar estudios previos relacionados con el diseño e implementación de sistemas inteligentes para la lectura de consumo eléctrico. La revisión permitió establecer los diferentes algoritmos para la detección de imágenes y las herramientas para realizar el entrenamiento de red neuronal, parámetros necesarios para el diseño del sistema.

Diseño del sistema


El estudio se basa en un sistema inteligente que tiene como objetivo disponer de la lectura en tiempo real del consumo de energía eléctrica, reduciendo la necesidad que el personal acuda a zonas de difícil acceso, para la toma de lecturas por parte de las empresas distribuidoras. El sistema, mediante una cámara, realiza la captura del *display* del medidor eléctrico, analiza las imágenes y se

obtiene una base de datos con la lectura de consumo; la solicitud de la lectura se genera mediante el envío de mensaje SMS.

Descripción general. Las imágenes recopiladas por la cámara son enviadas mediante comunicación serial a un controlador *Raspberry pi 4*, donde se ejecuta el modelo de detección, permitiendo la actualización de la base de datos gratuita y envío de un mensaje SMS con la lectura encontrada (Figura 1); la base de datos no solo contiene las lecturas numéricas, sino también las imágenes con las predicciones.

Figura 1

Diseño del sistema.

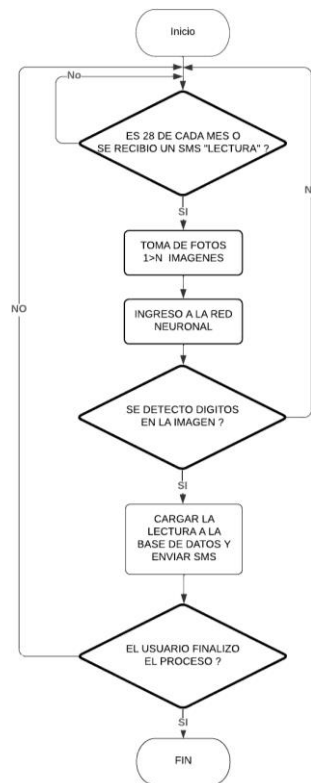


Fuente: autoría propia.

En la Figura 2, se describe los procesos que realiza el sistema para la lectura en tiempo real del consumo de energía eléctrica. Los medidores eléctricos, objeto del estudio, cuentan con *display* de tipo digital, que son los más comunes que se encuentran en Ecuador, tanto en la parte urbana como rural.

Figura 2

Flujo de trabajo del sistema de lectura inteligente de consumo energético.



Fuente: autoría propia.

Recopilación del dataset. Para la creación del conjunto de datos, se recopilaban imágenes del *display* de medidores digitales instalados en el Instituto Rumiñahui. En el medidor se realizó la adaptación de una cámara y se colocó el módulo con los elementos necesarios para la gestión y funcionamiento del sistema inteligente. El conjunto de datos contiene diversas lecturas del medidor, considerando que el consumo de la institución aumenta en los días laborables. La muestra analizada fueron 3000 imágenes (Figura 3), en las que existen varias clases con su respectiva etiqueta (Tabla 1).

Figura 3

Ejemplo de lecturas.



Fuente: autoría propia.

La resolución de las imágenes es de 1280x780 píxeles que fueron redimensionadas a 400x400 píxeles. Este proceso permite reducir el consumo de recursos de procesamiento, tomando en consideración las características limitadas de la *Raspberry pi 4*. Para facilitar la identificación de la predicción se creó etiquetas para las respectivas clases conforme la descripción de la Tabla 1.

Tabla 1

Clases del dataset.

Clase	Etiqueta	Número de muestras
0	0	1000
1	1	700
2	2	852
3	3	1000
4	4	940
5	5	850
6	6	741
7	7	842
8	8	741
9	9	800

Fuente: autoría propia.

Arquitectura. Para la ejecución del algoritmo se empleó *MobileNetV2*, arquitectura convolucional eficiente y ligera, diseñada para dispositivos móviles y embebidos, que en conjunto con *TensorFlow Lite*, permite ejecutar modelos de aprendizaje automático en dispositivos con recursos limitados (Figura 4).

Figura 4

Proceso MobileNetV2 y TensorFlow Lite.




Fuente: autoría propia.

MobileNetV2. Es una arquitectura de red neuronal convolucional diseñada para ser eficiente y precisa en dispositivos móviles y sistemas con recursos limitados. El proceso de *MobileNetV2* se puede dividir en varios pasos clave que permiten la clasificación y detección de imágenes de manera eficiente. Según Akay et al. (2021), la arquitectura de *MobileNetV2* consiste en repetir bloques de convolución invertida residual a lo largo de la red, con diferentes configuraciones de tamaño y número de filtros según la profundidad deseada y tamaño de la red.

Figura 5

Arquitectura MobileNetV2.



Fuente: (Akay et al., 2021)

Cada bloque de *MobileNetV2*, incorpora un factor de escala que controla la representación inmediata, permitiendo el equilibrio entre la precisión y la eficiencia computacional del modelo (Figura 5). El modelo divide en dos grupos de capas convolucionales: la convolución profunda y la convolución puntual.

La convolucional profunda toma cada uno de los canales de entrada para aplicar un filtro separado (kernel). Para una entrada con C_{in} canales y un filtro de tamaño $K \times K$, la convolución profunda produce C_{in} mapas de características diferentes. Cada canal de entrada se convoluciona con su propio filtro (kernel) para producir un mapa de características correspondiente.

$$Output(i,j) = \sum_{m=0}^{k-1} \sum_{n=0}^{k-1} input(i+m,j+n,c) Filter(m,n,c)$$

Donde:

(i,j)=píxeles de entrada

(kxk)=tamaño del filtro a aplicar

C_{in} =canal de entrada

La convolución puntual es la segunda de las etapas y consiste en aplicar una convolución estándar 1×1 a los mapas de características producidos por la convolución profunda. En otras palabras, cada píxel del mapa de características de salida se calcula como una combinación lineal de todos los píxeles de entrada en su posición correspondiente.

$$Output(i,j) = \sum_{c=0}^{C_{in}-1} input(i,j,c) Filter(c)$$

Donde:

(i,j)=ubicación de los píxeles de entrada

Filter (c)=Peso del filtro del canal c

Cin=canal de entrada

Tensorflow lite. Marco de trabajo que permite ejecutar modelos de aprendizaje automático en dispositivos con recursos limitados, como teléfonos móviles, microcontroladores y otros dispositivos integrados. Es una versión optimizada de *TensorFlow*, diseñada específicamente para inferencia en entornos de baja potencia y con requisitos de baja latencia. En el sistema diseñado, el modelo se entrena usando *TensorFlow* en un entorno con recursos suficientes. El modelo entrenado se convierte a un formato *TensorFlow Lite* (.tflite), usando el *TensorFlow Lite Converter*.

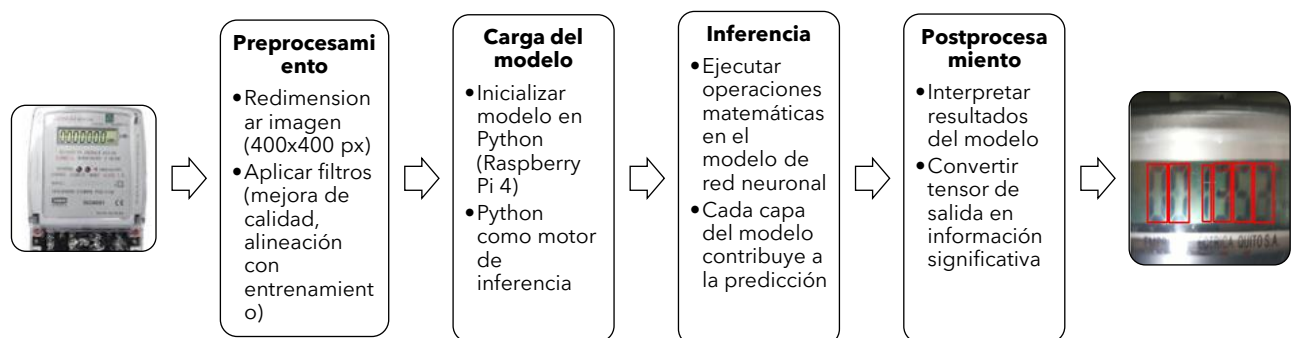
Finalmente, el modelo optimizado realiza inferencias directamente en el dispositivo, procesando datos en tiempo real o casi real y devolviendo los resultados de manera eficiente. Adicional, según Immonen & Hämäläinen (2022), *Tensorflow Lite* para controladores, se emplea para ejecutar inferencia de aprendizaje autónomo en un dispositivo y es compatible con múltiples lenguajes de programación; en el presente estudio se desarrolló con *Python*.

Implementación del sistema

Al disponer de una limitada capacidad de procesamiento en el controlador seleccionado, se opta por usar *Tensorflow Lite*, como *framework* de aprendizaje automático, para el entrenamiento y ejecución de *MobileNetV2*, dentro de la *Raspberry pi 4* (Figura 6).

Figura 6

Arquitectura implementada.



Fuente: autoría propia.

Entrenamiento. Para el análisis de lecturas, se tomó el total del *dataset* imágenes, divididas en un conjunto de entrenamiento de 2100 imágenes (70%) y un conjunto de validación de 900 imágenes (30%). La selección de las imágenes se desarrolló aleatoriamente para garantizar la diversidad de ambos conjuntos. Adicionalmente, se utilizaron 1000 imágenes de las técnicas de entrenamiento para la validación del modelo. El algoritmo de evaluación se desarrolló en Python, mientras que para el proceso de entrenamiento se utilizó *Google Colab* que es una

Astudillo Cortez, V., Pichoasamin Morales, D., Yugcha Quinatoa, W. y Moreira Bermeo, J. (2024).

Sistema inteligente para la lectura del consumo de energía eléctrica mediante visión artificial y comunicación GSM. *Revista Cotopaxi Tech*, 4(2), 36-52.

<http://ojs.istx.edu.ec/index.php/cotopaxitech/article/view/150>

julio - diciembre (2024) ISSN 2806-5573

plataforma gratuita que permite ejecutar códigos de Python y otros lenguajes de programación directamente desde el navegador web. *Colab* se basa en la nube de *Google* y proporciona acceso gratuito a recursos de hardware, como CPU, GPU y TPU. Estos recursos permiten acelerar la ejecución de código y la disminución del tiempo de entrenamiento, el cual contó con 900 iteraciones para minimizar el error en lo máximo posible.

Para la evaluación de la eficiencia y precisión del algoritmo, se presentarán cuatro índices de los posibles resultados obtenidos en la clasificación. La validación de los métodos de clasificación de imágenes, mediante visión artificial se utiliza una matriz de confusión.

Tabla 2

Matriz de confusión.

Valor Real	Predicción	
	Positivo	Negativo
Positivo	Verdadero Positivo (TP)	Falso Negativo (FN)
Negativo	Falso Positivo (FP)	Verdadero Negativo (TN)

Fuente: autoría propia.

En la Tabla 2, se presenta una síntesis de los resultados obtenidos mediante el uso del algoritmo, clasificándolos en cuatro categorías que describen la concordancia ente la predicción y el estado real del objeto analizado. Se define como verdadero positivo (TP), cuando la predicción del algoritmo y el estado real del objeto son positivos; falso positivo (FP), cuando la predicción es verdadera pero el valor real del objeto es negativo; verdadero negativo (VN), cuando la predicción y el valor real del objeto también lo es y falso negativo (FN), cuando el algoritmo predice negativo pero el valor real del objeto es positivo.

Al analizar estos valores en la matriz de confusión, se evalúa el rendimiento del algoritmo en la clasificación de diferentes clases de imágenes, así como la identificación de posibles errores de clasificación. Estos estados son aspectos fundamentales para calcular las métricas del modelo, como la Precisión (P), Sensibilidad (R) y la Sensibilidad media (mAP). Estas métricas proporcionan una evaluación cuantitativa del desempeño del algoritmo en la clasificación, lo que contribuye en una comprensión profunda de la fiabilidad y eficacia en los entornos de aplicación.

$$P = \frac{TP}{TP + FP} \cdot 100\%$$

$$R = \frac{TP}{TP + FN} \cdot 100\%$$

$$AP = \int_0^1 P(r) dr$$


$$mAP = \sum_{n=1}^N \frac{AP(n)}{N}$$

Para el cálculo y análisis de resultados de las variables, se empleó un conjunto de validación de 900 imágenes, que contienen diferentes estados de los dígitos del *display* del medidor eléctrico, completamente distintos al *dataset* de entrenamiento. El conjunto de imágenes se analizó imagen por imagen, llenando la matriz de confusión con base en los resultados de la clasificación realizada por el algoritmo. Al analizar cada imagen, se va clasificando dentro de la matriz de confusión, lo que permite validar la precisión y sensibilidad del algoritmo. Si la validación no fuese satisfactoria, se puede reentrenar para mejorar el desempeño.

En la Figura 7, se presenta los resultados del entrenamiento del modelo utilizando *Tensorflow Lite* para la validación de las clases. Dado que el modelo converge en 750 épocas, los resultados se presentan hasta ese punto. En cuanto a la precisión, se verifica que, para los datos de validación, el modelo logra resultados por encima del 92%, desde la época ciento cuarenta de entrenamiento, alcanzando un máximo de 95%, lo que valida la velocidad del modelo para obtener un resultado adecuado. En cuanto a la sensibilidad, se valida el número total de detecciones correctas en porcentaje, cuyo valor alcanzó un valor máximo de 93% durante el entrenamiento.

Figura 7

Comparación de métricas durante del entrenamiento.



Fuente: autoría propia.

3. RESULTADOS

Para la validación de resultados del algoritmo del sistema inteligente, se empleó un medidor de la empresa eléctrica Quito (EEQ) que se encuentra ubicado en el cantón Rumiñahui, con el objetivo de validar la eficiencia y sensibilidad del prototipo. En la Figura 8, se muestran resultados obtenidos de las predicciones; cabe resaltar que, dependiendo de la lectura, la calidad de luz cambia, pero el modelo es robusto para adaptarse a estos cambios.

Figura 8

Detección de dígitos del display del medidor eléctrico.



Fuente: autoría propia.

Para el análisis de la eficiencia, se examinó la configuración de la caja de anclaje y la selección de la función de pérdida para cada una de las clases. Los resultados obtenidos se presentan en una matriz de confusión que muestra los datos de las 300 imágenes analizadas (Figura 9), de las que se identificaron un total de 1800 posibles números. Además, se verificó que los resultados coincidieran con los enviados tanto a la base de datos, como al usuario seleccionado mediante mensaje SMS.

Figura 9

Resultados de la matriz de confusión.

		Verdadero	1720	40
		Falso	30	10
Estado Real			Verdadero	Falso
			Predicción	

Fuente: autoría propia.

Se determinó la precisión y sensibilidad de la detección de las lecturas de los medidores eléctricos, considerando la información base de datos del sistema, alcanzando una precisión del 95% y una sensibilidad del 93% (Tabla 3). Es importante considerar que los resultados varían dependiendo la cantidad de luz solar que presente y la posible aparición de reflejos.

Tabla 3

Precisión y sensibilidad por clase.

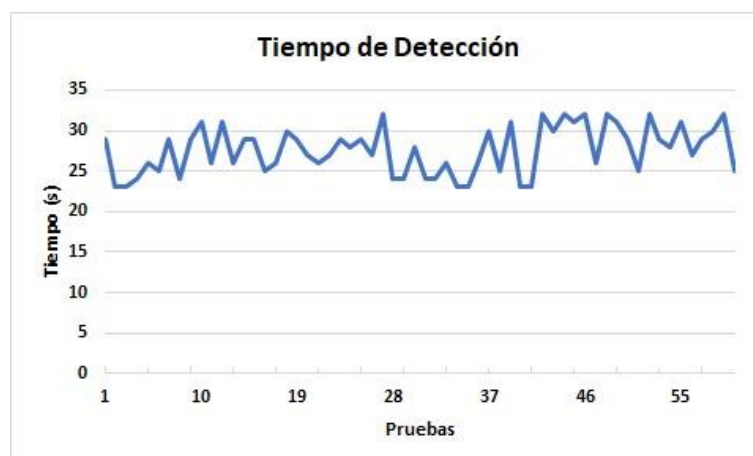
Clase	Precisión	Sensibilidad	mAP
0	0.98	0.96	0.90
1	0.95	0.90	0.92
2	0.96	0.92	0.91
3	0.97	0.94	0.93
4	0.94	0.96	0.94
5	0.96	0.95	0.92
6	0.94	0.94	0.93
7	0.97	0.92	0.91
8	0.98	0.93	0.92
9	0.92	0.95	0.92
Promedio	0.95	0.93	

Fuente: *autoría propia.*

Para validar el tiempo promedio del funcionamiento del proceso completo, que incluye la comunicación y generación de los resultados, se determinó un promedio de treinta segundos. Este tiempo abarca la lectura del mensaje SMS, el procesamiento de la imagen, la obtención de la predicción, su carga a la base de datos y envío de un nuevo SMS. Se realizaron varias pruebas para establecer este tiempo, como se muestra en la Figura 10.

Figura 10

Tiempo promedio detección de pruebas de lectura.



Fuente: *autoría propia.*

4. DISCUSIÓN

La implementación de un sistema inteligente para la lectura del consumo de electricidad, utilizando visión artificial y comunicación GSM, representa un avance significativo sobre los métodos tradicionales. Al integrar la tecnología de visión artificial con la comunicación GSM, el sistema puede capturar y analizar automáticamente la pantalla digital de un medidor de electricidad, proporcionando datos en tiempo real a las compañías de servicios públicos y a los consumidores. Este enfoque aborda varios problemas críticos, como los errores humanos en las lecturas manuales, los desafíos de accesibilidad en áreas remotas y los retrasos en el procesamiento de datos, criterio que concuerda con lo reportado por Santhosh et al. (2021), quien puntualiza que la lectura actual del uso de energía se realiza manualmente, moviéndose a las ubicaciones de los consumidores. Esto requiere una gran cantidad de operadores laborales y largas horas de trabajo para realizar la tarea.

El estudio destaca la importancia de crear un conjunto de datos robusto y seleccionar el modelo de aprendizaje para el sistema. Al recopilar 300 imágenes de pantallas de medidores digitales y etiquetarlas, el sistema puede alcanzar una alta precisión y sensibilidad en la lectura del consumo eléctrico. El uso de *MobileNetV2*, una arquitectura de red neuronal, combinada con *TensorFlow Lite*, permite un entrenamiento y ejecución efectivos del modelo en la *Raspberry Pi 4*. Según Leon et al. (2020), el entorno de Inteligencia Artificial admite marcos de aprendizaje profundos como *TensorFlow*, empleado para tareas de aprendizaje profundo como reconocimiento de imágenes. La utilización de una tarjeta *Raspberry Pi 4* y *MobileNetV2*, para el reconocimiento de imágenes y el procesamiento de datos, asegura que el sistema sea eficiente y capaz de funcionar en hardware, con recursos limitados y ocupando un mínimo espacio dimensional. Esta configuración garantiza que el sistema pueda operar en tiempo real, proporcionando datos de consumo precisos y oportunos.

Probabilidad de detección. Los resultados demuestran la efectividad del sistema, con una precisión del 95% y una sensibilidad del 93%. Estas métricas indican la fiabilidad del modelo en diferentes condiciones de iluminación y reflejos. La matriz de confusión y métricas de validación, muestran que el sistema puede identificar y leer correctamente los valores numéricos mostrados en los medidores. La implementación exitosa de este sistema inteligente tiene el potencial de transformar las prácticas de gestión energética, haciéndolas más eficientes y menos dependientes del trabajo manual. Esta innovación no solo mejora la precisión de la facturación, sino que también mejora la monitorización y gestión del consumo energético, contribuyendo a prácticas de uso de energía más sostenibles y eficientes.

Costo de comunicación GSM. Un aspecto relevante para considerar es el costo de la comunicación GSM en Ecuador. Cada solicitud de lectura de consumo genera un costo de 7 centavos de dólar por mensaje enviado y otros 7 centavos por la respuesta recibida. Este costo es un factor a tener en cuenta en la implementación y operación continua del sistema, ya que puede influir en la

Astudillo Cortez, V., Pichoasamin Morales, D., Yugcha Quinatoa, W. y Moreira Bermeo, J. (2024). Sistema inteligente para la lectura del consumo de energía eléctrica mediante visión artificial y comunicación GSM. *Revista Cotopaxi Tech*, 4(2), 36-52.
<http://ojs.istx.edu.ec/index.php/cotopaxitech/article/view/150>
julio - diciembre (2024) ISSN 2806-5573

viabilidad económica a largo plazo, especialmente en áreas con un gran número de medidores. Sin embargo, los beneficios en precisión, eficiencia y reducción de errores pueden justificar estos costos, proporcionando un sistema robusto y efectivo para la gestión energética.

5. CONCLUSIONES / CONSIDERACIONES FINALES

El presente artículo presenta un algoritmo de lectura para medidores de energía eléctrica mediante visión artificial, utilizando la arquitectura *Tensorflow Lite*. Este enfoque permite la toma con precisión y fiabilidad de las lecturas de medidores digitales. A través de un análisis experimental exhaustivo, se ha comprobado que la inclusión de capas convolucionales *MobileNetV2* para generar las cajas de anclaje, mejora significativamente la precisión y fiabilidad del algoritmo en la detección de fallas, alcanzando una tasa de precisión alrededor del 95%.

El tiempo promedio de detección de cada imagen, desde el envío de SMS hasta la carga de lectura en la base de datos es de 25 segundos. Este tiempo considera la velocidad de subida de los archivos y la disposición de la red GSM. El estudio destaca la importancia de la medición precisa de las lecturas de los medidores eléctricos. Las pruebas, realizadas durante un período de tres meses, arrojaron resultados favorables en la predicción de las imágenes de las lecturas, así como en la comunicación GSM y la integración con la base de datos. Esta integración permite la trazabilidad de las lecturas conforme a la solicitud del usuario o, por defecto, el algoritmo realiza el proceso una vez al mes.

El uso de este algoritmo reduce la necesidad de contar con personal dedicado a leer el medidor de cada usuario residencial, lo que reduciría los costos operativos para la empresa distribuidora. Además, minimiza los posibles errores, dado que permite obtener las lecturas en tiempo real, facilitando así la toma de decisiones informadas y la detección temprana de anomalías o fraudes. El algoritmo desarrollado presenta varias limitaciones. La fiabilidad y eficacia del proceso se reducen significativamente en condiciones de alta luminosidad. Además, el envío de lecturas depende de la calidad de la señal GSM en la zona de implementación del proyecto, lo que puede restringir su funcionalidad en áreas con baja cobertura.

Con dirección para futuras investigaciones futuras, se sugiere replicar este proyecto utilizando equipos más económicos para facilitar su implementación en áreas rurales, donde la lectura presencial es difícil, debido a la distancia y dificultades de acceso. Además, es recomendable realizar un estudio para mejorar el control de la iluminación natural y artificial que se presenta dentro del medidor, así como extender el periodo de prueba para evaluar la consistencia y fiabilidad del algoritmo. Finalmente, se debe explorar la viabilidad de utilizar alternativas de nuevas redes de comunicación para mejorar la cobertura y fiabilidad en áreas con baja conectividad GSM.

Se sugiere replicar este proyecto en zonas rurales de la provincia de Pichincha en Ecuador. Esta iniciativa permitiría evaluar la capacidad de adaptación del sistema a entornos con limitaciones de infraestructura y comunicación, así como

identificar posibles mejoras o ajustes necesarios para asegurar su óptimo funcionamiento en dichas condiciones. Estas pruebas podrían generar información valiosa sobre la escalabilidad y la robustez del sistema en diversos escenarios, lo que resultaría fundamental para su eventual implementación a gran escala en distintas regiones.

6. REFERENCIAS

- Akay, M., Du, Y., Sershen, C. L., Wu, M., Chen, T. Y., Assassi, S., Mohan, C., & Akay, Y. M. (2021). Deep Learning Classification of Systemic Sclerosis Skin Using the MobileNetV2 Model. *IEEE Open Journal of Engineering in Medicine and Biology*, 2, 104-110. <https://doi.org/10.1109/OJEMB.2021.3066097>
- Andino, J. (2023). Implementación de un sistema de verificación de consumo de energía. *Jurnal Sains Dan Seni ITS*, 6(1), 51-66.
- Andrade, Adonis, Lozada, L. (2022). *Diseño e implementación de un prototipo de medidor inteligente de energía eléctrica para consumos residenciales*.
- Cáceres Espinoza, J., Mamani Pari, D., & Apaza Huanca, P. (2022). Optimización de la eficiencia energética en los hogares, con microred fotovoltaica piloto, con tecnologías de medición inteligente en la ciudad del Cusco. *Ciencia Latina Revista Científica Multidisciplinar*, 6(5), 1667-1681. https://doi.org/10.37811/cl_rcm.v6i5.3178
- Cepeda, A. y Toapanta, C. (2023). *Diseño e implementación de un sistema portable para el registro de consumo de agua potable y energía eléctrica mediante procesamiento de imágenes* 356-363.
- Chávez, Alex, Herrera, E. (2020). Diseño e Implementación de una Smart Meter de Energía Eléctrica enlazado en una plataforma de visualización para Monitoreo y Control del consumo energético domiciliario basado en IoT. *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*, 53(9), 1689-1699.
- Coronel, Y. (2020). *Implementación de una aplicación para el registro de lectura de consumo de energía eléctrica mediante la captura de imágenes con un dispositivo móvil para el área de facturación de la empresa electro oriente S.A - JAÉN*. 1-215.
- Ferdin, John, Sarayut, Nonsiri, Annop, M. (2021). *Keras and TensorFlow: A Hands-On Experience*. August. <https://doi.org/10.1007/978-3-030-66519-7>
- Hernandez-Molina, E., Ojeda-Magana, B., Robledo-Hernandez, J. G., & Ruelas, R. (2020). Vision system prototype for inspection and monitoring with a smart camera. *IEEE Latin America Transactions*, 18(9), 1614-1622. <https://doi.org/10.1109/TLA.2020.9381804>
- Astudillo Cortez, V., Pichoasamin Morales, D., Yugcha Quinatoa, W. y Moreira Bermeo, J. (2024). Sistema inteligente para la lectura del consumo de energía eléctrica mediante visión artificial y comunicación GSM. *Revista Cotopaxi Tech*, 4(2), 36-52. <http://ojs.istx.edu.ec/index.php/cotopaxitech/article/view/150>
julio - diciembre (2024) ISSN 2806-5573

- Immonen, R., & Hämäläinen, T. (2022). Tiny Machine Learning for Resource-Constrained Microcontrollers. *Journal of Sensors*, 2022, 1-11. <https://doi.org/10.1155/2022/7437023>
- Jiménez, P. y Cabrera, J. (2020). Sistema de monitoreo remoto del consumo energético para hogares en la ciudad de Cuenca, basado en principios de IoT y servicios en la nube. 5(1), 443-458. <https://doi.org/10.23857/pc.v5i1.1949>
- Leon, V., Mouselinos, S., Koliogeorgi, K., Xydis, S., Soudris, D., & Pekmestzi, K. (2020). A TensorFlow Extension Framework for Optimized Generation of Hardware CNN Inference Engines. *Technologies*, 8(1), 6. <https://doi.org/10.3390/technologies8010006>
- López, R. D. J. (2020). Sistema para el monitoreo del consumo de energía eléctrica en tiempo real.
- Mejía, H. (2021). Lectura de medidores eléctricos analógicos mediante visión artificial. *Universidad Católica de Cuenca*, 1-71.
- Obando, N. (2022). Diseño e implementación de un sistema de medición y monitorización del consumo de energía eléctrica, para su integración en medidores de energía domiciliaria en la ciudad de El Ángel.
- Ortiz, L. (2023). Sistema domótico basado en inteligencia artificial para el control del consumo eléctrico y seguridad en residencias. 1-23.
- Pérez, R. R. (2023). Predicción de la demanda de energía eléctrica con aprendizaje automático.
- Sandoya, B. (2021). Sistema de monitoreo inteligente de consumo de energía eléctrica (Smart metering) con tecnología lora para hogares en la ciudad de ambato. *Industry and Higher Education*, 3(1), 1689-1699.
- Santhosh, C., Aswin Kumer, S. V., Gopi Krishna, J., Vaishnavi, M., Sairam, P., & Kasulu, P. (2021). IoT based smart energy meter using GSM. *Materials Today: Proceedings*, 46, 4122-4124. <https://doi.org/10.1016/j.matpr.2021.02.641>
- Shah MH, Khan S, Khan A, Khan I, Eldin SM. Sustainable energy management using the Internet of Things (IoT). *PLoS One*. 2023 Jun 20;18(6):e0283754. doi: 10.1371/journal.pone.0283754. PMID: 37339130; PMCID: PMC10281580.
- Villao, K. (2023). Diseño de un prototipo de sistema de monitoreo y predicción del consumo eléctrico en zonas residenciales usando redes neuronales artificiales.