

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivo

<https://doi.org/10.35381/i.p.v8i14.4882>

Optimización energética en entornos académicos mediante IoT y aprendizaje automático

Energy optimization in academic environments through IoT and machine learning

Elkin Alexander Morocho-Belduma
emorocho11@utmachala.edu.ec

Universidad Técnica de Machala, Machala, El Oro
Ecuador
<https://orcid.org/0000-0001-8306-8382>

Blade Steven Masache-Carrera
bmasache2@utmachala.edu.ec

Universidad Técnica de Machala, Machala, El Oro
Ecuador
<https://orcid.org/0000-0003-1240-0987>

Dixys Hernandez-Rojas
dhernandez@utmachala.edu.ec

Universidad Técnica de Machala, Machala, El Oro
Ecuador
<https://orcid.org/0000-0002-2116-6531>

Bertha Mazon-Olivo
bamazon@utmachala.edu.ec

Universidad Técnica de Machala, Machala, El Oro
Ecuador
<https://orcid.org/0000-0002-2749-8561>

Recibido: 20 de agosto 2025
Revisado: 08 de octubre 2025
Aprobado: 15 de diciembre 2025
Publicado: 01 de enero 2026

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

RESUMEN

El estudio tuvo como objetivo optimizar el consumo energético en un entorno académico mediante la integración de tecnologías IoT y técnicas de aprendizaje automático. Se diseñó e implementó un sistema de monitoreo en la sala de la carrera de Tecnologías de la Información, utilizando módulos de medición de energía y nodos ESP32 con sensores ambientales y de presencia, se registraron los datos en una base en tiempo real. Posteriormente, se aplicó un modelo predictivo basado en Random Forest para analizar los patrones de consumo y contrastarlos con la ocupación efectiva del espacio. El modelo alcanzó un desempeño adecuado y permitió identificar periodos de consumo no justificado. A partir de los escenarios simulados, se estimó un ahorro diario cercano a 2,75 kWh, equivalente a aproximadamente 60 kWh mensuales. En conclusión, el sistema demostró ser una alternativa viable y escalable, capaz de replicarse en otras aulas, laboratorios y espacios académicos similares.

Descriptores: Optimización energética; Internet de las cosas; aprendizaje automático; predicción de consumo eléctrico; entornos académicos. (Tesauro UNESCO).

ABSTRACT

The study aimed to optimize energy consumption in an academic environment by integrating IoT technologies and machine learning techniques. A monitoring system was designed and implemented in the Information Technology career room, using energy measurement modules and ESP32 nodes with environmental and presence sensors, the data was recorded on a real-time basis. Subsequently, a predictive model based on Random Forest was applied to analyse consumption patterns and contrast them with the effective occupation of the space. The model achieved adequate performance and allowed the identification of periods of unjustified consumption. Based on the simulated scenarios, a daily saving of close to 2.75 kWh was estimated, equivalent to approximately 60 kWh per month. In conclusion, the system proved to be a viable and scalable alternative, capable of being replicated in other classrooms, laboratories and similar academic spaces.

Keywords: Energy optimization; Internet of things; machine learning; electrical consumption prediction; academic environments. (UNESCO Thesaurus).

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

INTRODUCCIÓN

La gestión energética en los entornos académicos se ha convertido en un tema prioritario debido al aumento del uso de luminarias, computadoras y sistemas de climatización en espacios compartidos. En las salas de profesores, oficinas y laboratorios, estos equipos suelen permanecer encendidos incluso en períodos sin ocupación, lo que genera consumos residuales que no se ajustan a las necesidades del entorno. Esta situación se acentúa cuando la supervisión es manual, ya que dificulta regular el funcionamiento de los dispositivos conforme a los patrones efectivos de uso. Diversos estudios señalan que estas ineficiencias son frecuentes en instituciones educativas y que la falta de automatización contribuye de manera significativa al desperdicio energético (Ali et al., 2023; Peña de Loza y Ibarra-Villegas, 2024; Dinmohammadi et al., 2025).

Ante este panorama, las tecnologías basadas en Internet de las Cosas (IoT) ofrecen una alternativa eficaz para monitorear variables como consumo eléctrico, presencia y condiciones ambientales en tiempo real, lo que permite ajustar el uso de energía a la actividad real del espacio. Cuando estos sistemas incorporan modelos de aprendizaje automático, es posible identificar patrones de uso, anticipar la demanda y mejorar la toma de decisiones operativas. La literatura reciente destaca que la integración de IoT y machine learning ha logrado resultados relevantes en edificios inteligentes, aunque su aplicación en universidades latinoamericanas sigue siendo limitada por factores técnicos y presupuestarios (Eltamaly et al., 2021; Kumar Das., 2025; Mazon-Olivio y Pan, 2025).

En la Universidad Técnica de Machala (UTMACH), esta problemática se evidencia en la sala de profesores de la carrera de Tecnologías de la Información, donde no existen mecanismos automáticos para regular luminarias y sistemas de climatización. Como consecuencia, los equipos permanecen encendidos aun sin actividad, generando consumos innecesarios que incrementan la demanda eléctrica del espacio. Esta situación motivó el desarrollo de un sistema inteligente que permita monitorear y gestionar el consumo energético de forma continua y en función de la dinámica real del entorno

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

académico (Peña de Loza y Ibarra-Villegas, 2024).

La propuesta integra sensores de presencia, temperatura, humedad y módulos PZEM-004T conectados a microcontroladores ESP32 configurados con ESPHome, lo que permite obtener lecturas precisas en tiempo real. Los datos se envían a Firebase mediante un servicio intermedio que asegura su almacenamiento y evita exponer credenciales. Dado que esta arquitectura implica la transmisión y procesamiento continuo de información, es relevante considerar los riesgos propios de los ecosistemas IoT. En este punto, Cartuche Calva et al. (2023) ofrecen una taxonomía de activos que permite identificar amenazas y niveles de riesgo en sistemas distribuidos. El sistema también integra un módulo Broadlink IR vinculado a Alexa para el control de los aires acondicionados y paneles visuales instalados en tablets. Esta infraestructura se alinea con enfoques recientes de automatización IoT descritos por Paladines-Condoy et al. (2025) Colmenares-Quintero et al. (2024), y Flores et al. (2025). Durante la fase de diseño se compararon alternativas para la medición del consumo eléctrico, entre ellas Shelly EM, Sonoff POW y Tuya Smart Meter. El módulo PZEM-004T fue seleccionado por su precisión, compatibilidad con ESP32 y disponibilidad en el mercado local. Su desempeño ha sido validado en aplicaciones académicas y de monitoreo continuo, lo que respalda su elección para medir cargas de alta demanda como aires acondicionados y equipos informáticos.

La información obtenida por los sensores se visualiza mediante un panel táctil que permite supervisar el comportamiento energético del espacio y realizar ajustes manuales cuando es necesario. Esta infraestructura no solo facilita la caracterización del consumo real en la sala de profesores, sino que establece un modelo replicable y escalable que puede implementarse en otras salas, aulas, laboratorios y espacios académicos con condiciones similares (Jiang & Kurnitski, 2023; Baek & Seo, 2025; Eltamaly et al., 2021). A partir del análisis, el objetivo de la investigación es optimizar el consumo energético en un entorno académico mediante la integración de tecnologías IoT y técnicas de

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

aprendizaje automático.

MÉTODO

El estudio se desarrolló con un enfoque aplicado y cuantitativo, utilizando un diseño cuasi-experimental al evaluarse una intervención tecnológica en un entorno académico real. El proceso metodológico se organizó en cuatro fases: diagnóstico del entorno, diseño del sistema, implementación técnica y validación experimental. Para la gestión del desarrollo se empleó la metodología ágil SCRUM, lo que permitió trabajar por sprints, realizar seguimientos periódicos y ajustar tanto el hardware como el software de manera progresiva hasta lograr un funcionamiento estable del sistema en la sala de profesores.

A continuación, se describe cada una de las fases.

Fase 1. Diagnóstico del entorno

Se realizó el levantamiento de información sobre el consumo energético y las condiciones ambientales de la sala de profesores, con el fin de identificar el uso real de energía, temperatura, humedad y ocupación del espacio. Para ello se instalaron dos módulos PZEM-004T conectados a ESP32: uno en los breakers para registrar el consumo total y otro en el aire acondicionado principal para medir su demanda individual. Ambos realizaron lecturas cada 10 segundos y enviaron un registro consolidado por minuto a Firebase, lo que permitió establecer la línea base energética.

Las variables térmicas y de presencia se obtuvieron mediante tres nodos ESP32 con sensores DHT11 y LD2410C ubicados en esp-entrada, esp-pasillo-entrada y esp-pasillo-dashboard. Estos nodos midieron temperatura, humedad y ocupación con la misma frecuencia de muestreo, enviando también un registro por minuto. Cada lectura incluyó el identificador del sensor y la marca de tiempo en formato ISO (UTC-5), lo que facilitó el análisis de patrones y relaciones entre las variables monitoreadas. La Tabla 1 resume los sensores utilizados, su ubicación y los parámetros registrados en esta etapa.

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

Tabla 1.
Levantamiento de información inicial del sistema IoT.

Variable medida	Tipo de sensor / módulo	Nodo ESP32 / Ubicación	Frecuencia de muestreo	Unidad de medida / Campos registrados
Energía eléctrica	PZEM-004T v3	Prueba (breakers principales), energía-pasillo-entrada (aire acondicionado)	10 s (muestreo) / 1 min (registro)	Voltaje (V), Corriente (A), Potencia (W), Energía (kWh), Factor de potencia, Frecuencia (Hz), sensorId, timestamp ISO (UTC-5)
Temperatura ambiente	DHT11	Esp-entrada, esp-pasillo-entrada, esp-pasillo-dashboard	10 s / 1 min	Temperatura (°C), sensorId, timestamp ISO (UTC-5)
Humedad relativa	DHT11	Coincide con los nodos de temperatura	10 s / 1 min	Humedad relativa (% HR), sensorId, timestamp ISO (UTC-5)
Presencia y movimiento	LD2410C (radar mmWave)	Esp-entrada, esp-pasillo-entrada, esp-pasillo-dashboard	10 s / 1 min	Presencia (Sí/No), Presencia en movimiento (Sí/No), Presencia estática (Sí/No), Distancia de detección (cm), Distancia en movimiento (cm), Distancia estática (cm), Energía de detección en movimiento (unidad relativa), Energía de detección estática (unidad relativa), sensorId, timestamp ISO (UTC-5)

Elaboración: Los autores.

Fase 2. Diseño del sistema IoT

En esta fase se definió la arquitectura tecnológica del sistema inteligente, basada en el modelo clásico de tres capas IoT, lo que permite asegurar la modularidad, escalabilidad y mantenimiento del sistema de monitoreo y control energético, lo cual, el diseño se orientó a garantizar una comunicación fluida entre los sensores físicos, la red inalámbrica local y las plataformas de almacenamiento y automatización.

La Figura 1 presenta la arquitectura general del sistema, organizada en tres capas:

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio



Figura 1. Arquitectura IoT de tres capas

Elaboración: Los autores.

Capa de percepción

En la capa percepción se ubican los sensores encargados de registrar las variables energéticas, ambientales y de ocupación de la sala. Para el consumo eléctrico se emplearon módulos PZEM-004T conectados a ESP32, capaces de medir voltaje, corriente, potencia y energía acumulada. Además, se integraron sensores DHT11 para temperatura y humedad, junto con los módulos LD2410C basados en radar mmWave para la detección de presencia y movimiento. Todos los dispositivos se configuraron con

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

ESPHome, lo que permitió unificar la forma en que se obtuvieron las lecturas. La Figura 2 resume esta integración en un solo esquema.

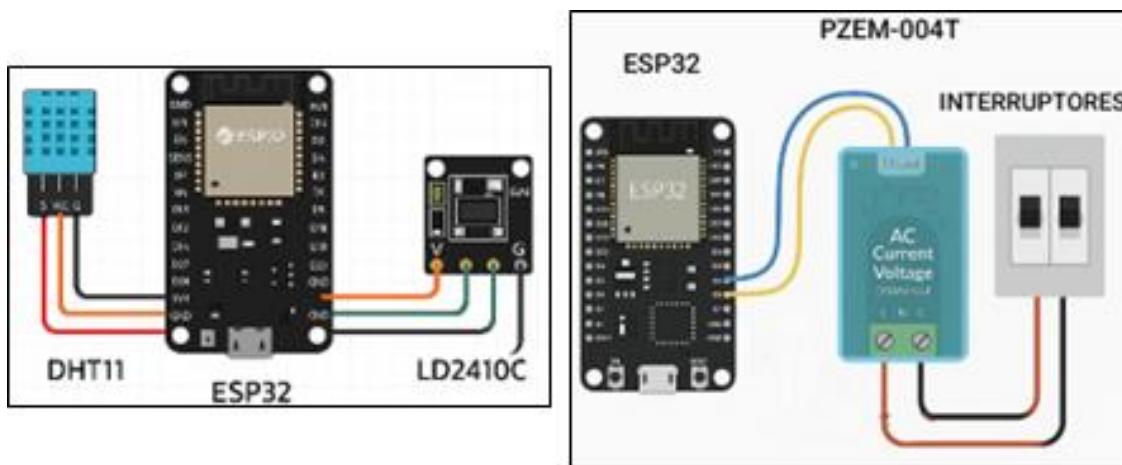


Figura 2. Integración de sensores PZEM-004T, DHT11 y LD2410C con ESP32.
Elaboración: Los autores.

Los nodos se instalaron en tres puntos estratégicos: “esp-entrada”, “esp-pasillo-entrada” y “esp-pasillo-dashboard”. Con esta distribución fue posible cubrir el acceso principal, el pasillo central y la parte interior donde permanecen los docentes. En total se colocaron cinco sensores: dos módulos PZEM-004T para diferenciar el consumo general y el del aire acondicionado, y tres nodos con DHT11 y LD2410C para obtener temperatura, humedad y presencia en zonas con diferentes condiciones ambientales.

En la Figura 3 se presenta el croquis tridimensional de la sala de profesores, donde se señalan las posiciones seleccionadas para los sensores de presencia LD2410C y los sensores ambientales DHT11. La sala cuenta con un área aproximada de 77 m², distribuida entre cubículos interiores, la zona de ingreso y un pasillo central donde se concentra la mayor parte del movimiento del personal docente.

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

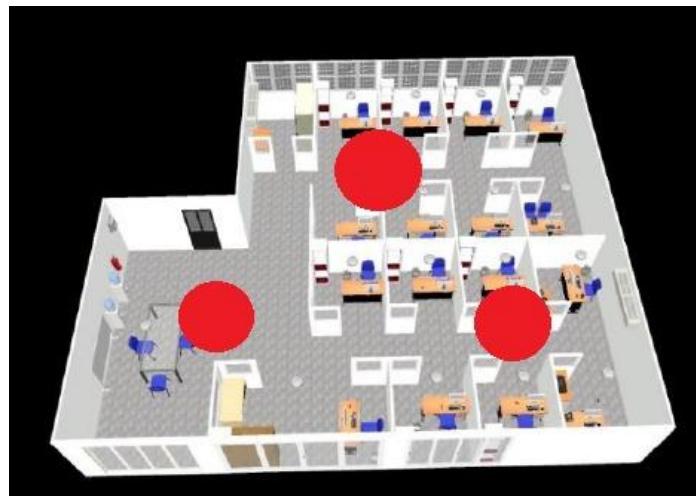


Figura 3. Croquis tridimensional de la sala de profesores con la ubicación de sensores.
Elaboración: Los autores.

Los sensores de presencia LD2410C tienen un alcance cercano a 5–6 m y un ángulo de detección de 120°. Su área efectiva se modeló como un sector circular:

$$A_{sensor} = \frac{120^\circ}{360^\circ} \pi \cdot (5 \text{ m})^2 \approx 26 \text{ m}^2$$

El área de la sala es:

$$A_{sala} \approx 11 \text{ m} \times 7 \text{ m} = 77 \text{ m}^2$$

Con estos valores, la cantidad mínima de sensores necesarios es:

$$N = \left\lceil \frac{A_{sala}}{A_{sensor}} \right\rceil = \left\lceil \frac{77}{26} \right\rceil = 3$$

Los tres sensores se colocaron en la “entrada”, el “pasillo central” y la “zona interior”, asegurando cobertura continua sin zonas ciegas.

En el caso de los sensores ambientales (DHT11), las variaciones térmicas internas requieren más de un punto de medición. Para salas superiores a 50 m², la literatura recomienda instalar un sensor cada 20–30 m². En este caso:

$$N_{DHT11} = \left\lceil \frac{A_{sala}}{30} \right\rceil = \left\lceil \frac{77}{30} \right\rceil = 3$$

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

Los DHT11 se ubicaron en “espentrada”, “esp-pasillo-entrada” y “esp-pasillo-dashboard”, zonas con condiciones diferentes por flujo de aire, apertura de puertas y equipos encendidos. Esto permitió obtener un perfil ambiental más representativo para correlacionarlo con el consumo energético.

Capa de red

La capa de red establece la comunicación inalámbrica mediante Wi-Fi, interconectando los nodos ESP32 con el servidor central. En lugar de enviar los datos directamente a Firebase, el sistema utiliza un servicio intermedio desarrollado en Node.js, distribuido como librería NPM por Gabriel Gorotiza, el cual implementa una API REST encargada de recibir las lecturas generadas por ESPHome y reenviarlas de forma segura hacia Firebase, evitando la exposición directa de credenciales y mejorando la gestión de múltiples solicitudes simultáneas.

La API organiza sus rutas en función del tipo de operación requerida. La Tabla 2 resume los principales endpoints utilizados para el registro y consulta de datos en la base de datos.

Tabla 2.

Endpoints usados en la base de datos.

Método	Endpoint	Descripción
POST	/api/lectura/:tipo/:sensorId	Guarda los datos de un sensor específico de un tipo determinado (energía, luz, etc.).
GET	/api/lectura/:tipo/:sensorId	Obtiene todas las lecturas de un sensor de cierto tipo.
GET	/api/sensores/:tipo	Lista los identificadores de sensores disponibles por tipo.
GET	/api/lecturas/:tipo	Devuelve todas las lecturas de todos los sensores de un tipo.
GET	/api/lecturas	Devuelve todas las lecturas de todos los sensores registrados.

Elaboración: Los autores.

El punto de envío configurado en los ESP32 correspondió a la ruta definida en el servicio intermedio: **firebase-sensor-server.onrender.com/api/lectura**

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

Este mecanismo permitió optimizar el flujo de datos provenientes de los distintos sensores, reducir la sobrecarga en Firebase y asegurar una comunicación estable entre los nodos y la plataforma de almacenamiento.

Capa de aplicación

En esta capa se gestionan los servicios de almacenamiento, supervisión y visualización de los datos recolectados por los sensores. El sistema utiliza Firebase Realtime Database como repositorio central, donde las lecturas de energía, temperatura, humedad y presencia se almacenan con su identificador y marca de tiempo.

El envío de datos desde los ESP32 se realiza mediante una API intermedia en Node.js, lo que permite estructurar las lecturas antes de enviarlas a Firebase, reducir la carga sobre los microcontroladores y proteger las credenciales de acceso. Para la supervisión local se integró Home Assistant, mientras que Node-RED permitió generar un panel visual accesible desde la sala para consultar en tiempo real el estado energético y ambiental. Esta capa también considera la futura incorporación de un modelo de aprendizaje automático entrenado con los datos históricos registrados en Firebase.

Por tanto, el modelo de tres capas se adoptó por su capacidad para separar funciones, reducir la complejidad y favorecer la escalabilidad del sistema.

- Capa de percepción: permite obtener datos precisos mediante sensores de bajo costo, distribuidos estratégicamente para cubrir el espacio.
- Capa de red: asegura un flujo de datos estable mediante un servicio intermedio que gestiona solicitudes múltiples y protege las credenciales de Firebase.
- Capa de aplicación: centraliza el almacenamiento, la supervisión y la visualización, facilitando el análisis técnico.

Fase 3. Captura y sincronización de datos en Firebase

La implementación inició con la configuración de los ESP32 en ESPHome, permitiendo integrar todos los sensores bajo los mismos parámetros de operación. Las lecturas se

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

tomaron cada 10 segundos y se enviaron en registros consolidados de un minuto para evitar acumulación de datos. En los nodos energéticos se configuró el PZEM-004T para medir voltaje, corriente, potencia y energía, mientras que en los nodos ambientales se incorporaron el DHT11 y el LD2410C para registrar temperatura, humedad y presencia. Cada lectura incluyó un sensorId y un timestamp en UTC-5, lo que aseguró la trazabilidad y el análisis conjunto entre consumo, condiciones ambientales y ocupación. El sistema opera mediante flujos independientes para cada variable monitoreada, todos siguiendo una secuencia común que incluye la captura, estructuración y envío de las lecturas hacia Firebase mediante el servicio intermedio. La Figura 4 resume este proceso general de adquisición y sincronización de datos.

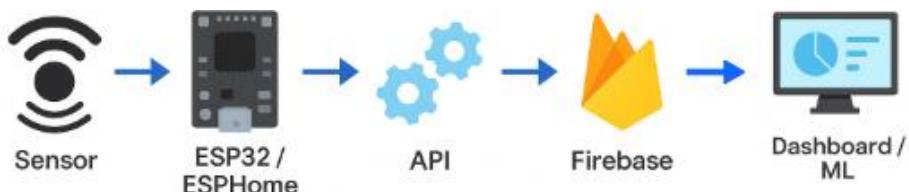


Figura 4. Flujo general de adquisición y sincronización de datos.

Elaboración: Los autores.

Los nodos “prueba” y “energía-pasillo-entrada” registran las mediciones del PZEM-004T y generan un paquete con las variables energéticas, el sensorId y el timestamp. Tal como se resume en la Figura 4, ESPHome estructura la lectura en formato JSON y la envía al servicio intermedio, reemplazando los valores cada 10 segundos y almacenando un registro definitivo cada minuto en Firebase, lo que permite identificar patrones de consumo por minuto, hora y día.

Los nodos “esp-entrada”, “esp-pasillo-entrada” y “esp-pasillo-dashboard” integran sensores DHT11 que registran temperatura y humedad. Siguiendo el procedimiento general ilustrado en la Figura 4, cada lectura se estructura en ESPHome, se envía al servicio intermedio y se almacena en Firebase con su timestamp correspondiente.

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

Los módulos LD2410C capturan presencia, movimiento y distancias dentro del área de detección, generando indicadores booleanos y valores en centímetros. Este proceso sigue la secuencia mostrada en la Figura 4, donde cada lectura se estructura, se valida y posteriormente se almacena en Firebase, permitiendo relacionar patrones de ocupación con los consumos energéticos registrados.

Para evitar conexiones directas entre los ESP32 y Firebase, lo cual habría expuesto credenciales sensibles y aumentado la carga computacional del microcontrolador, se incorporó un servicio intermedio en Node.js basado en una librería publicada en npm.

En Firebase, los datos se organizan de forma jerárquica para facilitar su consulta y análisis. Cada registro incluye un identificador de sensor (sensorId), el tipo de variable registrada, el timestamp en formato ISO y UNIX, y el conjunto de valores específicos según el dispositivo que generó la lectura, ya sea corriente, voltaje y potencia en el caso del monitoreo energético, temperatura y humedad en los sensores ambientales o indicadores de presencia y distancias en los módulos de radar. Esta estructura compacta permite identificar tendencias, comparar horarios y días completos, elaborar histogramas de uso y alimentar el análisis predictivo desarrollado en la fase posterior. La figura anterior muestra un ejemplo simplificado de la organización de estos datos dentro de la base.

Fase 4. Validación experimental y análisis de datos

Esta fase constituye el punto central del estudio, pues se enfoca en el análisis de los datos históricos almacenados en Firebase. Con la información recolectada por los sensores de energía, presencia y ambiente, se evaluó el comportamiento real de la sala de profesores y se contrastó con la línea base levantada en la Fase 1.

La Figura 5 muestra un fragmento del dashboard empleado para la consulta y filtrado de datos en tiempo real. Esta evidencia confirma que el sistema registró lecturas de manera continua durante varios días, consolidando un volumen de datos adecuado para el análisis estadístico.

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

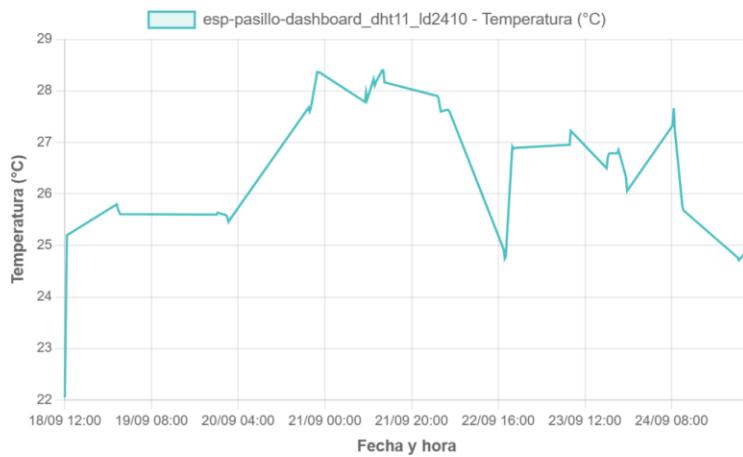


Figura 5. Evidencia de recolección de datos.

Elaboración: Los autores.

Con los registros recopilados se efectuó un análisis descriptivo considerando presencia por hora, consumo energético promedio y temperatura ambiente, organizado en la siguiente sección para identificar la relación entre ocupación y comportamiento energético.

Adicionalmente, la Figura 6 muestra cómo varía la presencia promedio por hora en relación con el consumo energético real.

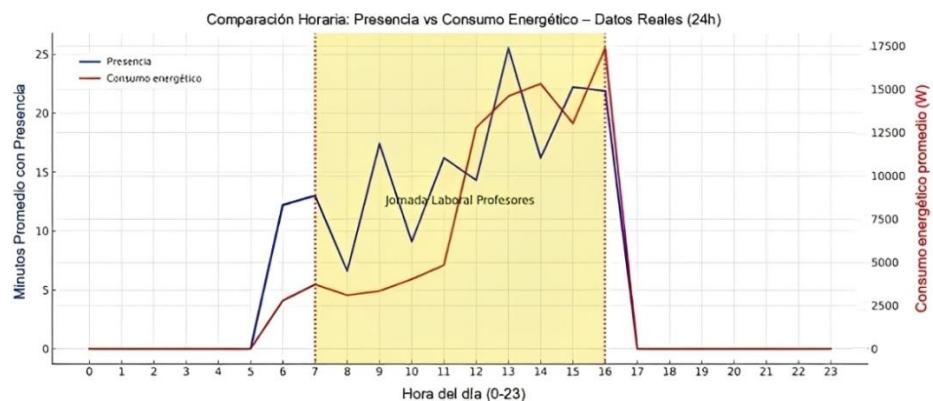


Figura 6. Comparación horaria presencia vs consumo.

Elaboración: Los autores.

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

En la mayor parte del día ambas curvas mantienen una tendencia similar, lo que refleja que el uso de luminarias, equipos informáticos y climatización responde en buena medida a la ocupación registrada. Sin embargo, se observan momentos específicos, sobre todo entre 06h00 y 09h00 y en algunos tramos entre 12h00 y 16h00, donde el consumo continúa elevado a pesar de que la presencia disminuye de forma notable. Después de las 17h00 la presencia desaparece y el consumo cae de manera inmediata, lo que confirma que las cargas principales se ajustan al horario laboral. Estas diferencias evidencian oportunidades claras de optimización, ya que revelan el funcionamiento innecesario de equipos durante períodos sin usuarios.

RESULTADOS

Desempeño del modelo de aprendizaje automático

Se entrenó un modelo de regresión Random Forest para predecir la potencia activa registrada por los módulos PZEM-004T, empleando como variables la hora del día, el día de la semana, el horario laboral y la presencia detectada por los sensores LD2410C. Los datos se dividieron en una partición 80/20 y el modelo alcanzó un MAE de 117 W y un RMSE de 172 W. La importancia de variables mostró que la hora del día aporta el 41,7 %, el día de la semana el 29,4 % y la presencia el 28,9 %, lo que confirma que el consumo está vinculado con la actividad académica y la ocupación real.

Para sustentar estas cifras, la potencia objetivo se obtuvo directamente de las lecturas del PZEM-004T aplicando:

$$P(t) = V(t) \cdot I(t)$$

Los registros reales oscilaron entre:

$$V(t) \approx 119 - 122V, \quad I(t) \approx 0.8 - 1.4 \text{ A}$$

lo que generó potencias instantáneas de:

$$P(t) \approx 95 - 170W$$

Cada potencia se promedió a nivel horario usando las ~60 lecturas generadas por minuto:

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

$$P_h = \frac{1}{n} \sum_{i=1}^n P(t_i)$$

Ejemplo real:

$$P_h(10:00 - 11:00) = 132W$$

Para garantizar consistencia, se descartaron valores atípicos que superaban ± 3 desviaciones estándar:

$$|P_i - \mu| > 3\sigma$$

Ejemplo aplicado:

$$\mu = 155, W, \quad \sigma = 18, W, \quad P_i = 225, W \rightarrow \text{eliminado}$$

Con el dataset depurado, cada árbol del bosque produjo una predicción:

$$\hat{y}_j = T_j(X)$$

y la salida final del modelo correspondió al promedio de los 200 árboles entrenados:

$$\hat{y} = \frac{1}{200} \sum_{j=1}^{200} \hat{y}_j$$

El rendimiento se evaluó mediante:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_j| = 116.9, W$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_j)^2} = 171.8, W$$

Estos resultados coinciden con los picos reales observados durante los transitorios del aire acondicionado (300–520 W), razón por la cual el modelo tiende a suavizar incrementos bruscos de corta duración. Aun así, la predicción permite identificar con claridad periodos en los que el consumo se mantiene elevado pese a la baja ocupación, lo que resulta útil para detectar ineficiencias operativas en la sala de profesores.

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

Escenarios de consumo y comparación entre operación real y optimizada

A partir del modelo entrenado se generaron dos escenarios, los cuales se resumen en la Figura 7. El primero reproduce las malas prácticas observadas en los datos reales, donde el consumo temprano se mantiene entre 130 y 150 W aun con baja ocupación, y después de las 11:00 alcanza picos de 600–700 W por el uso simultáneo de luminarias, equipos y climatización sin regulación. El segundo escenario simula una operación ajustada por presencia y horario, reduciendo los valores iniciales a 20–80 W y manteniendo consumos entre 200 y 400 W en los períodos de mayor actividad.



Figura 7. Predicción ML (Consumo alto vs optimizado y ahorro potencial).

Elaboración: Los autores.

La diferencia entre ambas curvas evidencia oportunidades de ahorro, especialmente entre las 12:00 y las 16:00, con reducciones de 450–600 W por hora. En conjunto, la Figura 7 muestra que los picos de desperdicio ocurren cuando los equipos permanecen encendidos sin relación con la ocupación, y que la combinación de sensores IoT y aprendizaje automático permite estimar con precisión el margen de optimización alcanzable mediante reglas basadas en presencia.

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

Cuantificación del ahorro energético en kWh y USD

Para cuantificar el impacto de ambos escenarios, las lecturas de potencia obtenidas con los sensores PZEM-004T se remuestrearon a un minuto y se calculó la potencia promedio por hora entre las 06:00 y 16:00. Estos valores se transformaron luego a energía (kWh) mediante la relación:

$$kWh = \frac{(potencia\ promedio\ (W) \times 1\ h)}{1000}$$

De estas potencias promedio se generaron dos perfiles: el escenario de malas prácticas, en el que los equipos permanecen encendidos más tiempo del necesario, y el escenario optimizado, que refleja una operación regulada por presencia y horario según el modelo de aprendizaje automático. El ahorro horario se obtuvo restando ambos valores:

$$Ahorro_{kWh} = Malas\ prácticas_{kWh} - Optimizado_{kWh}$$

El total diario corresponde a la suma de los once intervalos analizados, tal como se resume en la siguiente tabla.

Tabla 3.

Consumo real, malas prácticas y escenario optimizado (kWh).

Hora	Consumo real promedio (kWh)	Consumo malas prácticas (kWh)	Consumo optimizado (kWh)	Ahorro (kWh)
6	0.0485	0.1413	0.0154	0.1259
7	0.0647	0.1408	0.0807	0.0600
8	0.0540	0.1396	0.0798	0.0598
9	0.0582	0.1418	0.0385	0.1033
10	0.0700	0.1410	0.0841	0.0569
11	0.0842	0.1990	0.0568	0.1422
12	0.2228	0.5949	0.3612	0.2337
13	0.2554	0.7049	0.1335	0.5714
14	0.2796	0.6681	0.4129	0.2552
15	0.2379	0.7904	0.2182	0.5722
16	0.3170	0.7596	0.1843	0.5752
Total	1.6924	4.4214	1.6654	2.7558

Elaboración: Los autores.

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

Con base en estos resultados, el ahorro total para el día analizado alcanza aproximadamente 2,76 kWh, lo que proyectado a un mes equivale a cerca de 60,6 kWh de reducción. Esto representa un ahorro estimado de 0,28 USD diarios y 6,06 USD mensuales, tal como se muestra en la Tabla 4.

Tabla 4.
Resumen de ahorro energético (kWh y USD).

Métrica	Día	Mensual
Ahorro (kWh)	2.7559	60.6291
Ahorro (USD)	0.2756	6.0629

Elaboración: Los autores

Si bien el ahorro económico es modesto en un solo ambiente, los resultados confirman que el sistema IoT con aprendizaje automático identifica con precisión las malas prácticas de uso. Al aplicarlo en otros laboratorios o aulas, el ahorro acumulado se vuelve considerable y aporta a una gestión energética más eficiente en toda la institución.

DISCUSIÓN

El análisis realizado en la sala de profesores permitió identificar patrones de consumo que coinciden parcialmente con el horario académico, pero también evidenció picos de potencia en ausencia de usuarios. Este comportamiento ha sido reportado en otros entornos educativos donde la falta de automatización genera consumos residuales evitables, tal como señalan Barragán-Charry et al. (2022) y El-Khozondar et al. (2024). La integración del modelo Random Forest permitió caracterizar con mayor precisión estas variaciones y mostró métricas acordes con las obtenidas en investigaciones previas enfocadas en edificios académicos (Jiang & Kurnitski, 2023; Baek & Seo, 2025; Cujilema Paguay et al., 2023). La influencia de la hora, el día y la presencia concuerda con los estudios de Eltamaly et al. (2021) y Yilmaz y Kose (2024), quienes destacan que la

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivo

ocupación es un factor determinante en la demanda energética.

La comparación entre consumo real y predicho permitió identificar horas donde la potencia medida supera lo esperado para una ocupación normal, lo que sugiere prácticas operativas poco eficientes. Los escenarios simulados confirmaron estas diferencias, mostrando reducciones importantes cuando se utiliza un esquema de operación basado en presencia, en coherencia con trabajos recientes sobre gestión energética inteligente en edificios (Kumar Das, 2025; Poyyamozhi et al., 2024).

Los valores de ahorro diario y mensual obtenidos en este estudio demuestran que un sistema basado en IoT y aprendizaje automático puede cuantificar con claridad el impacto de las malas prácticas de uso y orientar decisiones para mejorar la eficiencia. Este resultado coincide con las tendencias actuales de integración entre sensores, firmware y plataformas IoT descritas por Mazon-Olivo y Pan (2024), Flores et al. (2025) y Paladines Condoy et al. (2024).

CONCLUSIONES

El sistema IoT implementado permitió caracterizar con claridad el comportamiento energético de la sala de profesores, identificando patrones de consumo asociados tanto al horario académico como a prácticas operativas poco eficientes. Estos registros constituyeron una línea base confiable para comprender cómo se distribuye la demanda eléctrica en un espacio real de uso docente.

La incorporación del modelo de aprendizaje automático fortaleció este análisis al predecir el consumo bajo diferentes condiciones de ocupación. Su desempeño permitió reconocer intervalos donde la potencia medida superó lo esperado, evidenciando oportunidades concretas para mejorar la gestión de cargas. Los escenarios simulados mostraron que una operación ajustada a presencia puede reducir de forma consistente el consumo diario y mensual, confirmando la viabilidad de estrategias de automatización para optimizar el uso energético sin afectar la actividad académica.

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

A partir de estos resultados, se proyecta que la incorporación de actuadores, reglas de desconexión y mecanismos automáticos basados en presencia permitiría cerrar las brechas detectadas.

FINANCIAMIENTO

No Monetario.

AGRADECIMIENTO

A todos los actores sociales involucrados en el desarrollo de la investigación.

REFERENCIAS CONSULTADAS

- Ali, A., Muqeet, H. A., Khan, T., Hussain, A., Waseem, M., & Niazi, K. A. K. (2023). IoT-Enabled Campus Prosumer Microgrid Energy Management, Architecture, Storage Technologies, and Simulation Tools: A Comprehensive Study. *Energies*, 16(4), 1863. <https://doi.org/10.3390/en16041863>
- Cujilema Paguay, J. A., Hidalgo Brito, G. A., Hernández Rojas, D. L., & Cartuche Calva, J. J. (2023). Secure home automation system based on ESP-NOW mesh network, MQTT and Home Assistant platform. *IEEE*, 21(7), 829-838. <https://doi.org/10.1109/TLA.2023.10244182>
- Baek, M., & Seo, Y. (2025). Hybrid forecasting of university electricity demand using time series and deep learning. *Energy and Buildings*, 347(Part B), 116400. <https://doi.org/10.1016/j.enbuild.2025.116400>
- Barragán-Charry, J., Silva-Londoño, J. J., Garcés-Quintero, C. S., Jaramillo-Ramírez, O. C., Hoyos-Daza, F., y Bravo-Gómez, L. C. (2022). Sistema de monitoreo de señales eléctricas y control automático para eficiencia energética con integración IoT. *Producción + Limpia*, 17(2), 53–71. <https://doi.org/10.22507/pml.v17n2a4>
- Cartuche Calva, J. J., Hernández Rojas, D. L., Morocho Román, R. F., y Radicelli García, C. D. (2023). Seguridad IoT: Principales amenazas en una taxonomía de activos. *Revista Hamut'ay*, 7(2), 51-59. <http://dx.doi.org/10.21503/hamu.v7i3.2192>

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivo

Colmenares-Quintero, R. F., Baquero-Almazo, M., Kasperezyk, D., Stansfield, K. E., y Colmenares-Quintero, J. C. (2024). Analysis of IoT technologies suitable for remote areas in Colombia: Conceptual design of an IoT system for monitoring and managing distributed energy systems. *Cleaner Engineering and Technology*, 21, 100783. <https://doi.org/10.1016/j.clet.2024.100783>

Dinmohammadi, F., Farook, A. M., y Shafiee, M. (2025). Improving energy efficiency in buildings with an IoT-based smart monitoring system. *Energies*, 18(5), 1269. <https://doi.org/10.3390/en18051269>

El-Khozondar, H. J., Mtair, S. Y., Qoffa, K. O., Qasem, O. I., Munyarawi, A. H., Nassar, Y. F., Bayoumi, E. H. E., & El Ahim, A. A. E. B. (2024). A smart energy monitoring system using ESP32 microcontroller. *e-Prime-Advances in Electrical Engineering, Electronics and Energy*, 9, 100666. <https://doi.org/10.1016/j.prime.2024.100666>

Eltamaly, A. M., Alotaibi, M. A., Alolah, A. I., & Ahmed, M. A. (2021). IoT-Based Hybrid Renewable Energy System for Smart Campus. *Sustainability*, 13(15), 8555. <https://doi.org/10.3390/su13158555>

Flores, J., Lima, I., y Hernández, D. (2025). Desarrollo del firmware IoT con Rust aplicando IA. *Revista Estudios y Perspectivas*, 5(2), 1993-2017. <https://doi.org/10.61384/r.c.a..v5i2.1255>

Jiang, Q., & Kurnitski, J. (2023). A machine-learning-driven framework for predicting electricity consumption in academic buildings. *Sustainable Cities and Society*, 97, 104723. <https://doi.org/10.1016/j.scs.2023.104723>

Kumar Das, D. (2025). Integrating IoT and AI for sustainable energy-efficient smart buildings. *Sustainability*, 17(22), 10313. <https://doi.org/10.3390/su172210313>

Mazon-Olivo, B., y Pan, A. (2024). Internet of Things: State-of-the-art, computing paradigms and reference architectures. *IEEE Latin America Transactions*, 20(1), 49-63. <https://latamt.ieeer9.org/index.php/transactions/article/view/5037>

Paladines-Condoy, J., Vera-Macías, J., y Hernández, D. (2024). Creación de un IDE web de gestión de firmware multilenguaje para un dispositivo IoT ESP32. *IBEROTECS*, 4(1), 77-87. <https://tech.iberojournals.com/index.php/IBEROTECS/article/view/643>

Peña de Loza, F., y Ibarra-Villegas, F. J. (2024). Implementación de tecnologías IoT para la reducción del consumo energético en oficinas inteligentes. *Revista de Ciencias Tecnológicas*, 7(3), e332. <https://doi.org/10.37636/recit.v7n3e332>

Elkin Alexander Morocho-Belduma; Blade Steve Masache-Carrera; Dixys Hernandez-Rojas; Bertha Mazon-Olivio

Poyyamozhi, M., Murugesan, B., Rajamanickam, N., Shorfuzzaman, M., & Aboelmagd, Y. (2024). IoT—A Promising Solution to Energy Management in Smart Buildings: A Systematic Review, Applications, Barriers, and Future Scope. *Buildings*, 14(11), 3446. <https://doi.org/10.3390/buildings14113446>

Yilmaz, S., y Kose, S. (2024). Sensor-based anomaly detection for electricity consumption using Random Forest models. *Energy Informatics*, 7(1), 28. <https://doi.org/10.1186/s42162-024-00331-1>

©2026 por los autores. Este artículo es de acceso abierto y distribuido según los términos y condiciones de la licencia Creative Commons Atribución-NoComercial-CompartirIgual 4.0 Internacional (CC BY-NC-SA 4.0) (<https://creativecommons.org/licenses/by-nc-sa/4.0/>).