



EDICIÓN 32
ENERO 2026

PANORAMA ELÉCTRICO 2026

PRESIDENTE DE LA REPÚBLICA

Daniel Noboa Azín

MINISTRA DE ENERGÍA Y MINAS

Inés María Manzano

VICEMINISTRO DE ELECTRICIDAD Y ENERGÍA RENOVABLE

Javier Medina Abarca

**DIRECTOR EJECUTIVO DE LA AGENCIA DE REGULACIÓN
Y CONTROL DE ELECTRICIDAD**

Fabricio Porras Ortiz

COORDINACIÓN NACIONAL DE REGULACIÓN ELÉCTRICA – ARCONEL

Danilo Ojeda Paz

**DIRECCIÓN TÉCNICA DE ESTUDIOS, INFORMACIÓN E INNOVACIÓN
– ARCONEL**

Andrés Chiles

CONSEJO EDITORIAL

Iván Sánchez Loor

Andrea Torres

Oscar Salazar

Christian Junia

DISEÑO Y DIAGRAMACIÓN

Sofía Andrade Torres

FOTOGRAFÍAS

Ministerio de Ambiente y Energía

Participantes del sector eléctrico

CITA ESTE DOCUMENTO COMO

©Panorama Eléctrico, Edición 32, Quito – Ecuador, enero 2026

Todos los derechos reservados

AUSPICIO

Banco Interamericano de Desarrollo – BID



©Agencia de Regulación y Control de Electricidad (ARCONEL)

Av. Naciones Unidas E7-71 y Av. Los Shyris, Edificio Cordiez 170506 /

Quito-Ecuador / Teléfono: (593) – 2 226 8744

www.arconel.gob.ec

La reproducción parcial o total de esta publicación, en cualquier forma y por cualquier medio mecánico o electrónico, está permitida siempre y cuando sea autorizada por los editores y se cite correctamente la fuente.

**Corte por deuda o falla técnica:
Detección automática a partir de imágenes con visión
artificial**

Capítulo 01

Corte por deuda o falla técnica: Detección automática a partir de imágenes con visión artificial



Bryan Jonathan Mayorga Márquez, Ing. Mgs
Empresa Eléctrica Ambato Regional Centro Norte S.A. - EEASA

Victor Hugo Cholota Hurtado, Ing.
Empresa Eléctrica Ambato Regional Centro Norte S.A. - EEASA

Resumen

Este trabajo describe la integración de un módulo de visión artificial en el bot institucional de la Empresa Eléctrica Ambato S.A. (EEASA), destinado a ampliar sus capacidades mediante la clasificación automática de imágenes de medidores para el diagnóstico de interrupciones del servicio. Se evaluaron rutas de procesamiento local y en la nube mediante modelos MobileNetV3, ViT-lite, GPT-4o Vision y Gemini Pro Vision, utilizando un conjunto experimental de 1 000 imágenes en local y 200 en nube, a partir de un universo de 70 mil registros. Se analizaron métricas de clasificación y tiempos de respuesta, observándose diferencias en el desempeño operativo de las rutas. El estudio aborda también aspectos técnicos y éticos para su aplicación en procesos de atención automatizados, y propone líneas de trabajo para la integración progresiva del módulo en el sistema de atención digital de la empresa.



1.1 Introducción

Las organizaciones evolucionan a través de dos tipos de procesos que coexisten y se complementan: optimización y transformación. La optimización busca mejorar lo que ya existe, incrementando la eficiencia de procesos establecidos. La transformación, introduce cambios estructurales que modifican la manera de operar y generan capacidades nuevas.

En la actualidad, la EEASA transita por una nueva etapa de transformación, impulsada por los avances en inteligencia artificial (IA). Como parte de esta estrategia, se ha desarrollado un módulo basado en visión artificial que permite clasificar imágenes de equipos de medición enviadas por los usuarios. Su propósito es contribuir a la identificación automatizada de interrupciones del servicio, distinguiendo entre suspensiones por falta de pago y fallas técnicas.

1.1.1 Identificación del problema



Uno de los problemas operativos que enfrenta la EEASA es la clasificación de las interrupciones del servicio reportadas por los usuarios. Muchos clientes no distinguen si el corte corresponde a una suspensión por falta de pago o a una falla técnica, lo que genera un volumen adicional de consultas.

Los registros históricos de los requerimientos por el canal de WhatsApp del centro de atención de la EEASA indican que, de 2 mil a 3 mil peticiones mensuales por WhatsApp, el 70 % corresponden a suspensiones por falta de pago.

El tratamiento manual de las imágenes enviadas por los clientes (aproximadamente 400 por semana) consume entre 13 y 20 horas de trabajo semanales, con un tiempo


promedio de 2 a 3 minutos por caso, impactando la eficiencia operativa.

1.1.2 Justificación

La atención al cliente en la EEASA ha evolucionado, a través de ciclos de optimización y transformación. El crecimiento sostenido de la base de clientes, de 5,965 en 1959 a cerca de 322,000 en la actualidad, ha aumentado el volumen de interacciones. El proceso manual de análisis de imágenes introduce un punto de fricción operativo. La automatización de este proceso es coherente con la estrategia de transformación digital de la empresa y con las tendencias del sector, donde la automatización puede reducir hasta en un 40 % las interacciones manuales [1], y el 66 % de las utilities han adoptado soluciones automáticas para informar y gestionar interrupciones [2].



Figura Nro. 1.1: Evolución de la atención al cliente en la EEASA: hitos de optimización y transformación.
Los porcentajes en los recuadros representan el crecimiento de la base de clientes en cada década.



1.1.3 Objetivo general



Desarrollar un sistema automatizado que permita diagnosticar, a partir de imágenes enviadas por el usuario, si una interrupción del servicio eléctrico corresponde a una suspensión por falta de pago o a una falla técnica, utilizando visión artificial y generando una respuesta inmediata a través de un bot conversacional.

1.1.3 Objetivos específicos



- Desarrollar un sistema de clasificación automática de imágenes que distinga entre interrupciones por falta de pago, fallas técnicas y estado normal.
- Diseñar y evaluar dos rutas de implementación (local y en la nube).
- Validar experimentalmente el desempeño del sistema con métricas estándar (precisión, recall, F1-score).
- Optimizar el proceso de análisis de imágenes, reduciendo los tiempos de revisión manual.
- Establecer las bases técnicas para una futura integración con los canales de atención digital (Chatbot Botie), en el marco de la estrategia de transformación digital de la EEASA.

1.1.5 Alcance


El proyecto incluye el desarrollo y validación de un sistema de clasificación en tres categorías, el procesamiento de imágenes a través de un canal piloto en Telegram, la evaluación de las rutas de procesamiento local y en la nube, y la generación de respuestas en formato estructurado. No incluye en esta fase la integración completa con los flujos productivos del bot corporativo.

1.2 Marco teórico

1.2.1 Inteligencia artificial y automatización del análisis visual


La inteligencia artificial (IA), y en particular el aprendizaje profundo (deep learning), a través de las redes neuronales convolucionales (CNN), han demostrado eficacia en tareas de clasificación, detección y segmentación de imágenes. La interrelación jerárquica entre IA, aprendizaje automático, deep learning y visión artificial puede observarse en la Figura 2.

Figura Nro. 1.2: Estructura conceptual de la inteligencia artificial y su relación con el aprendizaje automático, el aprendizaje profundo y la visión artificial [3].



En los últimos años, los avances en visión artificial se han acelerado notablemente. Según el AI Index Report 2025, la visión por computador es la segunda subárea con mayor volumen de publicaciones en IA, abarcando el 13.3% del total de artículos científicos del campo en 2023 [4] (véase la Figura 3). Esta tendencia refleja el interés sostenido por desarrollar sistemas capaces de extraer conocimiento directamente de datos visuales, con aplicaciones en sectores como manufactura, transporte, salud y servicios públicos.

Figura Nro. 1.3: Número de publicaciones en inteligencia artificial por subárea temática seleccionada, 2013-2023 [4].



El informe de Stanford también destaca el crecimiento exponencial de los modelos generativos multimodales, que integran visión y lenguaje. En 2024, estos modelos atrajeron inversiones privadas por más de \$33.9 mil millones, lo que representa un crecimiento del 18.7 % respecto a 2023 [4]. Este dinamismo ha favorecido la adopción de enfoques de aprendizaje auto-supervisado, transfer learning y entrenamiento con datasets de escala masiva, habilitando nuevas aplicaciones en diagnóstico visual automatizado, clasificación de eventos en campo y generación de respuestas a partir de imágenes.


1.2.2 Evolución del aprendizaje profundo en visión artificial

La visión artificial ha transitado desde las Redes Neuronales Artificiales (CNN), que capturan patrones espaciales locales de forma jerárquica, hasta los Vision Transformer (ViT) [5], que dividen la imagen en parches y utilizan mecanismos de atención para capturar relaciones globales.

Modelos más recientes como CLIP (Contrastive Language-Image Pre-training) o SAM (Segment Anything Model) [6] han introducidos capacidades multimodales y de segmentación universal, revolucionando el campo.

Esta evolución se visualiza en la Figura 4, que resume cronológicamente los avances desde las CNN tradicionales hasta la integración de modelos multimodales basados en transformers.

Figura Nro. 1.4: Evolución de arquitecturas en visión artificial y modelos multimodales [7].



1.2.3 Aplicaciones de visión artificial en el sector eléctrico

La visión artificial se utiliza en el sector eléctrico para mejorar el mantenimiento predictivo, la seguridad operativa y la supervisión en tiempo real. Empleando cámaras convencionales, redes neuronales profundas y procesamiento en el borde (Edge AI), se han desarrollado soluciones automatizadas para detectar fallas, monitorear equipos y prevenir incidentes. Las principales aplicaciones son:



Inspección automatizada: análisis visual de subestaciones y transformadores para identificar sobrecalentamientos, fugas o elementos extraños mediante CNN.



Lectura de controles: reconocimiento automático de instrumentos analógicos (termómetros, manómetros, interruptores) en ambientes remotos, ver Figura 1.5.

Figura Nro. 1.5: Detección automática de valores numéricos, luces e indicadores analógicos en panel eléctrico mediante visión artificial [8].



Supervisión de Equipo de Protección Personal (EPP): detección del uso adecuado de cascos, chalecos y guantes mediante modelos de detección por video, ver Figura 1.6.

Figura Nro. 1.6: Detección de personas y EPP en subestaciones mediante visión artificial [8].



Prevención de riesgos: detección en tiempo real de incendios, humo o accesos no autorizados usando análisis de video.




Inspección aérea: uso de drones con cámaras y modelos entrenados para identificar fallas en líneas de transmisión.



Monitoreo de seccionadores: verificación visual no intrusiva del estado de dispositivos de maniobra, ver Figura 1.7.

Figura Nro. 1.7: Monitoreo de seccionadores y detección de fallas en espaciadores. [8].



Supervisión remota: integración con sistemas SCADA para evaluar condiciones operativas y ambientales en subestaciones.

Plataformas como Viso Suite [8] permiten desplegar estos modelos a gran escala, integrándose con infraestructura existente y reduciendo costos operativos. Estas soluciones se alinean con la digitalización del sistema eléctrico y la transición hacia redes inteligentes resilientes.

Empresas como Aidon, Elenia y Ellevio han presentado experiencias reales en eventos como el Energy Vision Seminar 2024 [9][10], destacando el impacto de la IA en eficiencia, sostenibilidad y resiliencia.

1.2.4 Riesgos, desafíos y consideraciones éticas

La implementación de la visión artificial conlleva desafíos técnicos y éticos que deben ser gestionados desde el diseño.

Desde el punto de vista técnico, los modelos pueden verse afectados por variaciones ambientales (iluminación, clima, interferencias), lo que puede

impactar la fiabilidad del diagnóstico. Además, el despliegue a gran escala requiere interoperabilidad con sistemas SCADA y estrategias de actualización continua.

En cuanto a las consideraciones éticas, el AI Incident Database (AIID) [11] registró 233 incidentes en 2024, un aumento del 56.4 % respecto a 2023, muchos vinculados a errores de identificación y privacidad. Aunque el sector eléctrico no es el más afectado, la automatización creciente exige protocolos claros de responsabilidad y supervisión, en especial frente a eventos como suspensiones indebidas del servicio.


1.3 Metodología general

1.3.1 Flujo general del sistema

El sistema combina visión artificial, flujos conversacionales automatizados y pruebas en entorno real, con el objetivo de validar la viabilidad de una solución para la clasificación automática de interrupciones del servicio eléctrico a partir de imágenes enviadas por los usuarios (Figura 8).

El usuario envía una imagen a través de un bot, el sistema la procesa y devuelve una respuesta estructurada.

Figura Nro. 1.8: Diagrama de implementación del proyecto.



Datos empleados

Se utilizó un universo aproximado de 70 mil imágenes, seleccionando un subconjunto de mil imágenes, con la siguiente distribución de clases:

- Corte por deuda (sello rojo visible).
- Falla técnica (sin sello, indicadores de falla).
- Estado normal (sin fallas ni sello de corte).

El conjunto de datos se dividió en 60 % para entrenamiento, 20 % para validación y 20 % para prueba.

Arquitectura general del sistema

Se exploraron dos rutas complementarias para la clasificación automática de imágenes:

- **Ruta local:** se realizaron pruebas preliminares con la arquitectura LLaVA 1.5 7B HF, utilizando cuantización QLoRA en 4 bits. Debido a las limitaciones de hardware, las pruebas se ejecutaron en un entorno controlado en Google Colab. Para el procesamiento local, se explora el uso de modelos optimizados como MobileNetV3 y ViT-lite, que permiten un balance entre precisión y eficiencia.
- **Ruta en la nube:** el sistema se conecta a APIs de modelos multimodales con capacidades de visión, en particular GPT-4o Vision y Gemini Pro Vision. La integración se realizó mediante un flujo automatizado desarrollado en Google Apps Script, orquestado a través de un bot en la plataforma Telegram.

Integración conversacional

El flujo de integración se implementó mediante el bot en Telegram, que permite la interacción directa con el usuario. El bot guía al usuario en el envío de imágenes, gestiona el preprocesamiento, comunica con la API seleccionada y presenta la respuesta en formato legible y estructurado.

Además, se desarrolló un esquema de extracción automática de las respuestas JSON para facilitar su posterior integración con sistemas corporativos y de análisis, incluyendo interacciones con el sistema PME para verificar condiciones operativas en tiempo real y con SAP para consultar el estado de deuda de los clientes, complementando así el diagnóstico automático proporcionado por el modelo de visión.

1.3.2 Diseño del bot conversacional

El bot, desarrollado en Telegram, actúa como interfaz para recibir imágenes y entregar resultados.

Para la generación de respuestas, se utiliza un prompt que solicita a la API de visión (GPT-4o o Gemini Pro Vision) una respuesta en formato JSON predefinido, garantizando consistencia para el procesamiento automático posterior.

La estructura solicitada es:

```
{  
  "sello_rojo": true/false,  
  "sello_amarillo": true/false,  
  "led_encendido": true/false,  
  "numeros_medidor": [ ...],  
  "lecturas_medicion": [ ...]  
}
```

El bot procesa este JSON y construye dinámicamente un texto en lenguaje natural para el usuario, siguiendo reglas de mapeo definidas.

Adicionalmente, en sistemas conversacionales generales, las respuestas pueden generarse mediante dos enfoques:

- Uso de reglas condicionales y formatos predefinidos, como en este sistema.
- Empleo de modelos secuenciales que aprenden la probabilidad de la secuencia de salida dada la entrada, tal como se muestra en la siguiente Ecuación 1:

$$P(x|y) = \prod_{t=1}^T P(y_t|y_1, \dots, y_{t-1}, x)$$

Ecuación 1

Este enfoque permite una mayor cobertura lingüística, aunque con menor control semántico. En el sistema propuesto, se prioriza el control semántico y la consistencia de las respuestas, por lo que se adopta el enfoque basado en plantillas estructuradas complementadas con generación automática controlada.

Dado un archivo de imagen 1 en formato binario (por ejemplo, PNG o JPEG), su codificación en Base64 se expresa como la siguiente Ecuación 2:

$$Base64(I) = Encode_{64}(Bytes(I))$$

Ecuación 2

donde Bytes(I) representa la secuencia de bytes del archivo original.

Para alimentar correctamente modelos de visión por computadora, como redes neuronales convolucionales (CNN), las imágenes deben poseer dimensiones fijas. El redimensionamiento consiste en transformar la imagen original $I \in \mathbb{R}^{H \times W \times C}$ a una dimensión estándar $I' \in \mathbb{R}^{h \times w \times c}$ donde:

- *H, W son el alto y ancho originales,*
- *h, w son las dimensiones requeridas por el modelo (por ejemplo, 224×224 píxeles),*
- *C es el número de canales (usualmente 1 para escala de grises o 3 para RGB).*

El redimensionamiento se puede expresar como una función de interpolación, tal como se detalla en la Ecuación 3:

$$I'(x', y') = I(f_x(x'), f_y(y'))$$

Ecuación 3

donde son f_x y f_y son funciones de mapeo inverso para interpolar píxeles desde la imagen original.

La normalización es una transformación lineal de los valores de intensidad de píxeles, cuyo objetivo es centrar la distribución de valores alrededor de cero y escalarla a una varianza controlada. Esta operación mejora la estabilidad numérica del entrenamiento de modelos y reduce la sensibilidad a condiciones de iluminación.

Sea una imagen $I \in \mathbb{R}^{h \times w \times C}$, cuyos valores de intensidad $I_{x,y,c}$ están en el intervalo $[0, 255]$. La normalización a media μ y desviación estándar σ se define como se detalla en la Ecuación 4:

$$I^{\wedge}_{x,y,c} = \frac{I_{x,y,c} - \mu_c}{\sigma_c}$$

Ecuación 4

donde μ_c y σ_c son parámetros calculados globalmente (en un conjunto de entrenamiento) o por canal.

1.3.3 Arquitectura del modelo de visión artificial

Se emplearon Redes Neuronales Convolucionales (CNN) y modelos basados en Transformadores Ligeros (ViT-lite).

La entrada son imágenes preprocesadas (redimensionadas a 224×224×3 y normalizadas).

Una imagen de entrada se representa como un tensor definido por la Ecuación 5:

$$X \in \mathbb{R}^{h \times w \times c}$$

Ecuación 5

donde h , ω son la altura y el ancho de la imagen, y C es el número de canales (usualmente 3 para imágenes RGB).

La salida es un vector de probabilidades para las clases:

→ $y1$: Corte por deuda

→ $y2$: Falla técnica

→ $y3$: Estado normal

A continuación, se expone las capas de la arquitectura.

a. Capa Convolutiva

La operación de convolución extrae características espaciales mediante filtros entrenables que se aplican localmente sobre la imagen o sobre los mapas de activación intermedios. La operación puede expresarse matemáticamente como la siguiente Ecuación 6:

$$S_{(i,j)} = (X * K)(i,j) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} X(i+m, j+n) \cdot K(m,n)$$

Ecuación 6

donde:

→ X : entrada local

→ K : kernel o filtro convolutivo de tamaño $M \times N$

→ $S(i,j)$: salida del mapa de características en la posición (i,j) .

b. Función de Activación ReLU

La activación no lineal introduce capacidad de modelar relaciones complejas. La función ReLU (Rectified Linear Unit) se define como se detalla en la siguiente Ecuación 7:

$$f(x) = \max(0, x)$$

Ecuación 7

Esta función activa únicamente valores positivos, manteniendo propiedades computacionales favorables como no saturación y eficiencia.

c. Capa de Pooling

El pooling reduce la dimensionalidad espacial manteniendo las características más salientes. En el caso de max-pooling se define en la siguiente Ecuación 8:

$$P(i,j) = \max_{(m,n) \in \Omega(i,j)} A(m,n)$$

Ecuación 8

donde $\Omega(i,j)$ representa la vecindad local en la entrada A para la posición (i,j) .

d. Capa de Clasificación Softmax

La salida final es un vector de probabilidades correspondiente a clases mutuamente excluyentes: corte por deuda, falla técnica, estado normal. La función softmax transforma los valores del último vector denso $z=[z_1, z_2, \dots, z_K]$ en probabilidades, tal como se define en la Ecuación 9.

$$\sigma(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}$$

Ecuación 9

para $i=1, 2, \dots, K$

1.3.4 Evaluación del modelo

El desempeño se evaluó utilizando métricas derivadas de la matriz de confusión:

a. Precisión (Precision)

Proporción de predicciones positivas correctas. Se define como:

$$Precisión = \frac{TP}{TP + PF}$$

Ecuación 10

donde:

- **TP: Verdaderos positivos,**
- **FP: Falsos positivos**

Una precisión elevada indica baja tasa de falsos positivos, lo cual es relevante cuando se desea evitar clasificaciones erróneas que desencadenen inspecciones innecesarias.

b. Sensibilidad o Recall

Proporción de positivos reales identificados correctamente, tal como se detalla en la siguiente ecuación:

$$Recall = \frac{TP}{TP + FN}$$

Ecuación 11

donde:

- **FN: Falsos negativos.**

c. Puntaje F1 (F1-score)

Media armónica de precisión y sensibilidad que balancea ambas métricas:

$$F1 = 2 \frac{Precisión \cdot Recall}{Precisión + Recall}$$

Ecuación 12

Este valor oscila entre 0 y 1, donde valores más altos representan mejor desempeño global en la clase evaluada.

1.4 Rutas de implementación

Se exploraron dos rutas de implementación para la clasificación de imágenes:


1.4.1 Opción 1: Implementación local

i) Infraestructura empleada

La implementación en infraestructura local implica la instalación y operación de servidores físicos, que requieren componentes de hardware para almacenamiento, unidades de procesamiento gráfico (GPU) para la ejecución del modelo, y software para la gestión de colas, APIs y acceso de usuarios.

Cada imagen es recibida a través del bot desarrollado en la plataforma de mensajería Telegram. A través de un script implementado en Google Apps Script, se gestiona la integración entre el bot y el entorno de procesamiento local, donde se realiza el análisis de la imagen (Figura 9).

Figura Nro. 1.9: Diagrama de implementación de forma local.



Una vez recibida la imagen (Figura 10), esta es transferida al servidor local para su procesamiento. En las pruebas realizadas, se verificó que el modelo es capaz de procesar la imagen y extraer información visual relevante.

Figura Nro. 1.10: Equipo de medición que dispone de un sello color rojo.



Para ejecutar modelos multimodales de gran tamaño como LLaVA, que permiten obtener resultados estructurados en formato JSON (sello, LEDs, numeración, lecturas), es necesario contar con una capacidad de memoria RAM superior a 30 GB, lo cual excede la configuración actual del entorno de pruebas.

Como solución intermedia, se realizaron pruebas utilizando el modelo Salesforce/blip-image-captioning-base, a través del pipeline image-to-text. La Figura 11 muestra un ejemplo de la salida obtenida, donde el modelo genera un texto descriptivo general —en este caso: "a meter on the ground next to a wall"—. Si bien no se obtienen aún los campos estructurados requeridos, la descripción confirma que el modelo detecta correctamente la presencia del equipo de medición en la imagen, lo que valida la viabilidad de la arquitectura propuesta. La limitación observada refuerza la necesidad de optimizar la infraestructura local para permitir la ejecución completa de modelos multimodales más avanzados.

Figura Nro. 1.11: Ejemplo de resultado de análisis de imagen mediante la pipeline image-to-text en el servidor local.

```
Load the model using pipeline

We will leverage the image-to-text pipeline from transformers !

from transformers import pipeline

pipe = pipeline("image-to-text", model="Salesforce/blip-image-captioning-base")
result = pipe(image_path)
result

[5]: ✓ 53.5s Open 'result' in Data Wrangler Python

W0611 15:19:22.188000 52880 site-packages\torch\distributed\elastic\multiprocessing\redirects.py:29] NOTE: Redirects are currently not supported in Windows or MacOS
c:\Users\bmayorga.DISTRIBUCION\conda\envs\VISION_LLAVA\Lib\site-packages\huggingface_hub\file_download.py:943: FutureWarning: 'resume_download' is deprecated and w
warnings.warn(
c:\Users\bmayorga.DISTRIBUCION\conda\envs\VISION_LLAVA\Lib\site-packages\transformers\generation\utils.py:1133: UserWarning: Using the model-agnostic default 'max_
warnings.warn(

[{'generated_text': 'a meter on the ground next to a wall'}]
```

ii) Integración del bot y procesamiento

Se realiza mediante un flujo automatizado.

Cada imagen es enviada por el usuario a través del bot desarrollado en la plataforma Telegram. Mediante un script desarrollado en Google Apps Script, se gestiona la descarga de la imagen y su transferencia al entorno local de procesamiento.

El procesamiento de la imagen se ejecuta en el servidor local. Cuando las capacidades de hardware lo permiten (memoria RAM suficiente), es posible ejecutar modelos multimodales avanzados como LLaVA. En el entorno de pruebas actual, debido a las limitaciones de RAM, se utilizaron modelos optimizados como Salesforce/blip-image-captioning-base a través de la pipeline image-to-text, permitiendo validar el flujo completo.

La respuesta generada por el modelo es capturada y enviada nuevamente al bot, que la presenta al usuario. Además, el flujo de integración se diseñó para permitir la extracción automática de la respuesta en formato JSON,

facilitando su posterior integración con sistemas corporativos como SAP y con los registros de estado energético obtenidos desde el sistema PME de Schneider Electric, que ya se ha integrado de manera piloto para usuarios de la zona de subestaciones en Ambato.


1.4.2 Implementación en la nube con APIs (ChatGPT/Gemini)

i) Arquitectura del sistema

Los servicios de inteligencia artificial en la nube ofrecen alta capacidad de cómputo y escalabilidad, permitiendo procesar imágenes desde cualquier ubicación con conectividad a internet.


En este esquema, las imágenes son recibidas a través del bot en Telegram y procesadas mediante un script desarrollado en Google Apps Script. La imagen se transfiere a los servicios en la nube (ChatGPT o Gemini), donde es analizada. La respuesta es posteriormente enviada de nuevo al bot y presentada al usuario (Figura 12).

Figura Nro. 1.12: Diagrama de implementación con servicios en la nube.



Para la creación y configuración del bot se utilizó la herramienta oficial BotFather [12]. El bot se diseñó con botones de control que permiten gestionar el flujo conversacional, como se muestra en la Figura 13.

Figura Nro. 1.13: Botones configurados en Visibot.



ii) Estructura del prompt

En este proyecto, el prompt fue diseñado como una estructura de entrada explícita, implementada directamente en el flujo automatizado del bot conversacional, con el fin de obtener una respuesta estructurada y directamente utilizable.

El bot, recibe imágenes enviadas por los usuarios. Estas imágenes son descargadas mediante la API de Telegram, convertidas a formato Base64, y enviadas a la API de OpenAI GPT-4o junto con el siguiente prompt detallado, incluido en el código:

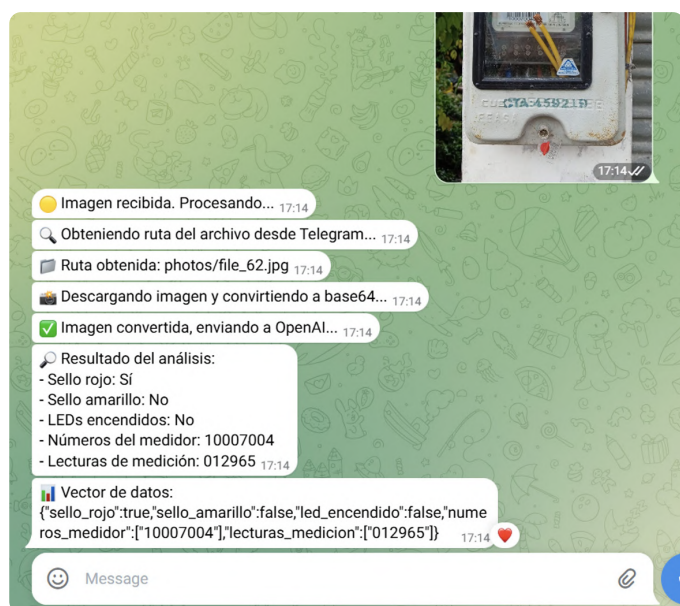
```
Analiza la imagen del medidor eléctrico.
Devuélveme los siguientes datos en formato
JSON estructurado y claro. La respuesta debe
contener un objeto JSON con los siguientes
campos:
{
  "sello rojo": true o false, // true si hay un sello
  rojo (corte por falta de pago)
  "sello amarillo": true o false, // true si hay un
  sello amarillo (sin corte por falta de pago)
  "led encendido": true o false, // true si hay
  uno o dos LEDs encendidos
  "numeros medidor": ["..."], // lista de números
  identificados como numeración del medidor
  "lecturas medicion": ["..."] // lista de números
  que parecen ser valores de medición (en
  display o cinta)
}
Si no detectas algún elemento, indica su valor
como false o como lista vacía []. No agregues
explicaciones ni comentarios, solo
devuélveme el JSON solicitado.
Imagen:
```

Este diseño garantiza que el modelo comprenda con precisión el contexto de análisis y que la respuesta se entregue en un formato controlado y estandarizado. De esta forma, los resultados pueden ser consumidos automáticamente por los sistemas corporativos y utilizados en flujos de automatización y análisis interno (ver Figura 14 y Figura 15).

Figura Nro. 1.14: Imagen característica de un equipo de medición con corte.



Figura Nro. 1.15: Respuesta al usuario, luego del proceso ejecutado en los servicios de la nube.



1.5 Resultados y análisis

Los resultados obtenidos en la fase experimental permiten comparar el desempeño de las rutas de implementación exploradas: procesamiento local con modelos optimizados y procesamiento mediante APIs en la nube. Para esta etapa, se seleccionaron 200 imágenes etiquetadas manualmente a partir del conjunto disponible, con el fin de evaluar la viabilidad técnica en condiciones representativas. La selección consideró un balance aproximado de clases ($\approx 33\%$ para cada categoría: corte por deuda, falla técnica y estado normal), de modo que las métricas reflejaran la capacidad del sistema para distinguir correctamente entre las distintas condiciones operativas.

El proceso de etiquetado manual fue realizado por personal técnico de la EEASA, validando visualmente cada imagen conforme a criterios previamente definidos y consistentes con los estados operativos requeridos. Esta metodología garantiza que los resultados obtenidos reflejan un comportamiento alineado con los requisitos reales de operación.

La Tabla 1 resume las métricas de evaluación principales, los tiempos de procesamiento y la capacidad de respuesta estructurada observada en ambos entornos.

Tabla Nro. 1: Resultados comparativos (fase experimental, 200 imágenes).

Criterio técnico	Local básico	Local con Colab	Nube (GPT 4o Vision)	Nube (Gemini Pro Vision)
Precision (promedio ponderado)	0.70	0.78	0.88	0.85
Recall (promedio ponderado)	0.60	0.72	0.87	0.80
F1 Score (promedio ponderado)	0.64	0.75	0.81	0.82
Tiempo promedio por imagen	6.0 s	4.2 s	1.8 s	2.0 s
% de respuestas estructuradas válidas	90 %	93 %	98 %	96 %
% de respuestas inconsistentes	10 %	7 %	2 %	4 %

En la ruta local básica, se empleó un modelo de captioning visual (Salesforce/blip-image-captioning-base) que no permite generar directamente las tres clases estructuradas. Por lo tanto, las métricas reportadas en esta ruta corresponden a un análisis posterior basado en clasificación semántica de los captions obtenidos, y no son directamente comparables con las métricas obtenidas con modelos de clasificación directa en las demás rutas.

En la ruta Local con Colab, las métricas reportadas corresponden a la ejecución de modelos optimizados de clasificación de imágenes, específicamente MobileNetV3 y ViT-lite, entrenados y validados sobre el subconjunto balanceado de 200 imágenes. Los resultados presentados reflejan el mejor desempeño obtenido entre estas arquitecturas, considerando tanto precisión, recall, F1-score como tiempos de procesamiento.

Adicionalmente, se presenta en la Tabla 2 la matriz de confusión obtenida para la ruta Nube (GPT-4o Vision), que constituye la opción con mejor desempeño global. Esta matriz refuerza la capacidad del modelo para discriminar entre las distintas clases operativas. La matriz evidencia un desempeño equilibrado en la clasificación de las tres clases, con tasas de acierto superiores al 85 % en cada una y un bajo nivel de confusión entre categorías operativas adyacentes.

Tabla Nro. 2: Matriz de confusión – GPT-4o Vision (fase experimental, 200 imágenes).

Clase real: Clase predicha	Corte por deuda	Falla técnica	Estado normal
Corte por deuda	58	2	3
Falla técnica	4	52	4
Estado normal	2	5	50

Interpretación

El procesamiento en la nube a través de APIs mostró ventajas significativas en todas las métricas. GPT-4o Vision alcanzó un F1-score de 0.81 y tiempos de respuesta de 1.8 segundos, superando notablemente a las soluciones locales. La mejora en el F1-Score implica una reducción tangible de errores de clasificación, y la disminución en los tiempos de inferencia permite una interacción conversacional fluida.

1.6 Conclusiones

- El proyecto demostró que la visión artificial permite automatizar el análisis de imágenes para la gestión de interrupciones del servicio eléctrico. La solución facilita la clasificación entre cortes por falta de pago, fallas técnicas y estados normales.
- La evaluación comparativa evidenció que las rutas basadas en APIs en la nube presentan un desempeño superior en precisión, consistencia y velocidad, proporcionando una base técnica sólida para la futura integración de esta funcionalidad en los canales digitales de la empresa.

1.7 Recomendaciones

- Continuar con la evaluación y ajuste progresivo de la arquitectura implementada, considerando el balance entre desempeño técnico, escalabilidad y sostenibilidad operativa.
- Avanzar con la integración de la solución en el canal de WhatsApp institucional, aprovechando su alta penetración en la base de usuarios y su complementariedad con los canales ya existentes.
- Consolidar la integración de los resultados del sistema con los flujos de atención digital y con los sistemas corporativos de soporte, fortaleciendo la trazabilidad operativa.
- Establecer un proceso de revisión periódica del desempeño de los modelos de visión artificial utilizados, con el fin de incorporar mejoras tecnológicas y garantizar la vigencia de la solución en escenarios de operación dinámica.

Referencias

- [1] S. McTear , «Transforming interactive voice response systems in utilities,» McKinsey & Company, 25 09 2020. [En línea]. Available:
<https://www.mckinsey.com/industries/electric-power-and-natural-gas/our-insights/transforming-interactive-voice-response-systems-in-utilities>.
- [2] Silverblaze, «Build Customer Satisfaction with Utility Notifications,» Silverblaze, 23 04 2020. [En línea]. Available:
<https://www.silverblaze.com/blog/build-customer-satisfaction-with-utility-notifications/>.
- [3] IIC, «Instituto de Ingeniería del Conocimiento,» [En línea]. Available: www.iic.uam.es.
- [4] AI Index Report 2025, «Stanford Institute for Human-Centered Artificial Intelligence,» Stanford University, Mar. 2025.
- [5] A. Dosovitskiy, L. Beyer, A. Kolesnikov, D. Weissenborn, X. Zhai, T. Unterthiner, M. Dehghani, M. Minderer, G. Heigold, S. Gelly, J. Uszkoreit y N. Houlsby, «An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale,» International Conference on Learning Representations (ICLR), 2021.
- [6] A. Kirillov, E. Mintun, N. Ravi, H. Mao, C. Rolland, L. Gustafson, T. Xiao, S. Whitehead, A. C. Berg, W. Y. Lo, Q. V. Le. y R. Girshick, «Segment Anything,» Computer Vision and Pattern Recognition, 2023.

Referencias

- [7] A. Shin, M. Ishii y T. Narihira, «Perspectives and Prospects on Transformer Architecture for Cross-Modal Tasks with Language and Vision,» 2024.
- [8] Viso.ai, «Popular applications of computer vision in energy and utilities,» Viso.ai, [En línea]. Available: <https://viso.ai/applications/computer-vision-in-energy-and-utilities-industry/>. [Último acceso: 06 05 2026].
- [9] Energy Vision, «Energy Vision,» [En línea]. Available: <https://energy-vision.org/events/>. [Último acceso: 05 06 2025].
- [10] Aidon, «Aidon's Energy Vision seminar discussed the role of AI in the management of electricity grids,» 13 09 2024. [En línea]. Available: <https://aidon.com/aidons-energy-vision-seminar-discussed-the-role-of-ai-in-the-management-of-electricity-grids/>. [Último acceso: 05 06 2025].
- [11] AIID, «Incident List,» AI Incident Database, [En línea]. Available: <https://incidentdatabase.ai/summaries/incidents/>. [Último acceso: 05 06 2025].
- [12] Telegram, «core.telegram.org,» 05 06 2025. [En línea]. Available: <https://core.telegram.org/bots/api>. [Último acceso: 05 06 2025].
- [13] A. Radford, J. W. Kim, C. Hallacy, A. Ramesh, G. Goh, S. Agarwal, G. Sastry, A. Askell, P. Mishkin, J. Clark y I. Sutskever, «Learning Transferable Visual Models From Natural Language Supervision,» Proceedings of the 38th International Conference on Machine Learning (ICML), vol. 139, pp. 8748-8763, 2021.
- [14] M. Caron, H. Touvron, I. Misra, H. Jégou, J. Mairal, P. Bojanowski y A. Joulin, «Emerging Properties in Self-Supervised Vision Transformers,» Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), pp. 9650-9660, 2021.
- [15] I. Goodfellow, Y. Bengio y A. Courville, Deep Learning, MIT Press, 2016.
- [16] M. A. Nielsen, Neural Networks and Deep Learning, Determination Press, 2015.
- [17] D. P. Kingma y J. Ba, «Adam: A method for stochastic optimization,» Proc. Int. Conf. Learning Representations (ICLR), 2015.
- [18] Prabhu, Understanding hyperparameters and its optimisation techniques, Towards Data Science, 2018.
- [19] A. Monteux, Metrics for semantic segmentation, Excursions in data, 2022.
- [20] Chatbot Arena, «Chatbot Arena,» [En línea]. Available: <https://chatbotarena.com/>. [Último acceso: 05 06 2025].
- [21] Lmarena, «Prompt. Vote. Advance AI,» [En línea]. Available: <https://lmarena.ai/>. [Último acceso: 05 06 2025].
- [22] Jeff Winter, «Transformation Vs. Optimization,» Jeff Winter, 06 08 2024. [En línea]. Available: <https://www.jeffwinterinsights.com/insights/transformation-vs-optimization-video>.

Creando el Gemelo Digital de la Red de Quito: Metodología y Alcances del Levantamiento LiDAR de la EEQ

Capítulo 02

Creando el Gemelo Digital de la Red de Quito: Metodología y Alcances del Levantamiento LiDAR de la EEQ



Santiago Medina
Director Técnico, KAWSUS



Nicole Vizuite
Operador GIS, KAWSUS

2.1 Introducción

En la actualidad, la energía eléctrica no solo constituye un servicio esencial para garantizar la calidad de vida, sino también como un motor clave del desarrollo económico. Este sector impulsa las inversiones, fomenta la creación y modernización de industrias generadoras de empleo y se consolida como una base fundamental para el bienestar social [1]. Gobiernos y empresas del sector energético, trabajan de manera conjunta en el diseño de políticas que respondan a las necesidades reales de la población, cumplan con los compromisos ambientales y aseguren el acceso universal a la electricidad.

En Ecuador, el sector eléctrico ha experimentado en los últimos años un proceso de transformación orientado a modernizar la infraestructura de generación, transmisión y distribución, garantizando un servicio confiable y eficiente [2].

Las prácticas tradicionales de inspección de redes eléctricas, basadas en la observación directa y la topografía clásica, presentan limitaciones significativas. Estas técnicas generan altos costos operativos, exponen a los trabajadores a riesgos y, debido a su lentitud, reducen la frecuencia de recolección de datos. A ello se suma el error humano, que deriva en registros incompletos o inexactos [3]. Como consecuencia, la planificación de mejoras y la eficiencia del mantenimiento se ven seriamente afectadas.

Para superar estas barreras, la tecnología LiDAR (Light Detection and Ranging) se ha consolidado como una solución innovadora en la gestión automatizada de redes eléctricas [4]. Este sistema de teledetección activa permite generar representaciones tridimensionales del terreno en forma de nubes de puntos de alta precisión, facilitando el análisis detallado de la geometría y la identificación de componentes de la red mediante escaneos realizados desde satélites, aeronaves, vehículos o estaciones terrestres [5].

El objetivo central de este trabajo es desarrollar un gemelo digital de la red de Quito, mediante una metodología basada en datos LiDAR. Este modelo busca convertirse en la nueva base de datos oficial para la Empresa Eléctrica Quito (EEQ), optimizando la detección y clasificación de la infraestructura y contribuyendo a la modernización y optimización del sector energético.

2.2 Metodología


Las organizaciones evolucionan a través de dos tipos de procesos que coexisten y se complementan: optimización y transformación. La optimización busca mejorar lo que ya existe, incrementando la eficiencia de procesos establecidos. La transformación, introduce cambios estructurales que modifican la manera de operar y generan capacidades nuevas.

2.2.1 Diseño del Levantamiento Multimodal

El diseño metodológico se ajustó a las condiciones topográficas del Distrito Metropolitano de Quito, caracterizado por cotas que oscilan entre los 2.400 y 3.100 msnm, así como por la diversidad de sus entornos, que incluyen áreas urbanas densamente pobladas, áreas periurbanas y sectores rurales. Para abordar esta complejidad, se implementó una estructura en cuatro fases, orientada a garantizar la precisión y la eficiencia del levantamiento.

La Figura 1 presenta el diagrama flujo correspondiente al proceso de levantamiento y actualización de la topología de la EEQ.

Figura Nro. 2.1: Diagrama de Flujo de la Metodología propuesta



2.2.2 Socialización

La estrategia integral de socialización, se ejecutó en estrecha coordinación con la EEQ, abarcando dos ámbitos complementarios. Externamente, se desarrolló una campaña de comunicación que incluyó la instalación de banners informativos y la capacitación del personal del call center para atender consultas ciudadanas. Internamente, se implementó una planificación técnica detallada que contempló la gestión de accesos, la definición de protocolos de seguridad y la logística operativa para el levantamiento de datos en todos los sectores. Esta doble vía aseguró la transparencia ante la comunidad, facilitó las labores en campo y resultó fundamental para la correcta adopción y divulgación de la iniciativa.

2.2.3 Planificación técnica de levantamiento

La planificación de rutas constituyó la etapa inicial y estratégica del proceso de levantamiento de la red eléctrica, sobre la cual se estructuró toda la logística de captura de datos en campo. Este componente fue determinante para garantizar eficiencia operativa, cobertura total del sistema y precisión en los resultados obtenidos.

El proceso se basó en la información geográfica oficial proporcionada por la Empresa Eléctrica Quito (Figura 2), proveniente de su Base Corporativa, que reúne cartografía institucional, la red eléctrica existente y registros geoespaciales de infraestructura. A partir de este insumo, se realizó un análisis espacial orientado a identificar corredores eléctricos, zonas de difícil acceso, áreas con alta concentración de activos y sectores priorizados por criterios técnicos o estratégicos.

La planificación también incluyó la asignación de tramos por cuadrillas y la definición de cronogramas operativos

sincronizados con las condiciones ambientales y el tráfico eléctrico. Esta organización permitió mantener una secuencia lógica en las jornadas de levantamiento, garantizando un flujo constante de información hacia la base de datos central y reduciendo la probabilidad de duplicidad o pérdida de registros.

Figura Nro. 2.2: Mapa de rutas Alimentador 59E.



2.2.4 Captura de Datos Multimodal

Se adoptaron dos metodologías complementarias: LiDAR terrestre, para garantizar precisión en áreas urbanas y LiDAR aéreo para cobertura en zonas rurales.

El levantamiento de la red eléctrica mediante LiDAR terrestre se realizó a partir de la información preliminar y los mapas de rutas definidos en la etapa de planificación, asegurando la correcta identificación y georreferenciación de todos los tramos y elementos críticos de la red. Para ello, vehículos equipados con sensores láser recorrieron las trayectorias siguiendo mapas digitales integrados en aplicaciones con Sistemas de Posicionamiento Global (GPS).

Como plataforma móvil, se adaptó un vehículo SUV

equipado con el sistema de escaneo láser Maverick de Teledyne Optech, una decisión acertada para la topografía del Distrito Metropolitano. Este sistema integró en tiempo real un escáner LiDAR multieco, cámaras RGB y una unidad IMU, garantizando la precisión geométrica de cada medición (Tabla 1).

Tabla Nro. 2.1: Especificaciones técnicas para el levantamiento con LiDAR Terrestre

Parámetro Técnico	Valor Considerado
Velocidad de desplazamiento	≤ 40 km/h
Inclinación del sensor LiDAR	$\geq 10^\circ$ (orientación oblicua hacia el lateral del vehículo)
Frecuencia de escaneo	10 Hz - 20 Hz
Densidad de nube de puntos	≥ 100 puntos/m ² (variable según entorno)
Precisión de medición	± 3 cm - ± 5 cm
Campo de visión horizontal	360° (escáner rotativo) o $\geq 90^\circ$ (escáner fijo de alta densidad)
Campo de visión vertical	20° - 30°
Resolución angular (vertical/horizontal)	0.1° - 0.3°
Número de retornos por pulso	≥ 2 retornos
Rango efectivo del sensor	50 m - 150 m
Sistema de posicionamiento	GNSS + IMU (GPS diferencial y unidad inercial)
Condiciones de operación	-10 °C a +40 °C, resistente a vibraciones e ingreso de polvo (IP 65 o superior)

La segunda metodología utilizada para el levantamiento de la red eléctrica consiste en el empleo de plataformas aéreas no tripuladas (RPAS), equipadas con sensores LiDAR de precisión. La planificación de las misiones de vuelo se realiza mediante la carga de archivos cartográficos en el sistema de navegación del RPAS.

A partir de esta información geoespacial, se define la altitud de operación, ajustada dinámicamente según las variaciones del terreno y la altura del dosel vegetal, garantizando una distancia constante respecto al suelo (AGL) y un Ground Sample Distance (GSD) óptimo (Tabla 2).

Tabla Nro. 2.2: Especificaciones técnicas para levantamiento con LiDAR Aéreo


Parámetro Técnico	Valor Considerado
Velocidad de viento	12 m/s
Superposición frontal	40%
Superposición lateral	70%
Sensor fotogramétrico	Zenmuse L1
Altura de vuelo	hasta 400 pies

El sensor LiDAR incorporado, permite múltiples retornos por pulso (hasta cinco) [6], lo que posibilita la captura de información tanto del terreno, como de la vegetación intermedia y de la infraestructura aérea, incluyendo postes, transformadores, seccionadores, acometidas y conductores (Figura 3).

Figura Nro. 2.3: LiDAR terrestre y aéreo. (1 de 2)



Figura Nro. 2.3: LiDAR terrestre y aéreo. (2 de 2)



Una vez concluida la misión de vuelo, los datos obtenidos se descargan y se someten a un proceso de postproducción que incluye: filtrado de ruidos, clasificación automática de retornos (terreno, vegetación, estructuras), generación del Modelo Digital de Terreno (MDT) y del Modelo Digital de Superficie (MDS), así como la validación topológica mediante software especializado. Posteriormente, esta información se integra en plataformas SIG corporativas, lo que permite realizar análisis geoespaciales de alta precisión, modelar riesgos asociados a la proximidad de vegetación, verificar distancias mínimas de seguridad entre conductores y planificar proyectos de mantenimiento o expansión de la red.

2.2.5 Procesamiento y Control de Calidad

Esta etapa es crítica, ya que convierte la información bruta capturada en campo en datos listos para análisis, modelado e integración en plataformas SIG.

→ Recepción, organización y georreferenciación

Las nubes de puntos obtenidas para cada tramo o alimentador se organizan y validan mediante un proceso de ajuste espacial, que incluye:

- Corrección y ajuste de coordenadas absolutas mediante GNSS diferencial (RTK o PPK)
- Revisión de solapamientos entre franjas adyacentes
- Alineación temporal y espacial para asegurar continuidad entre sesiones de captura.

Cada archivo se renombra siguiendo un esquema estandarizado que asegura trazabilidad, control de versiones y facilita auditorías e integraciones posteriores. Además, se verifica la integridad de los archivos, su formato (habitualmente LAS o LAZ) y la densidad mínima de puntos definida en la planificación técnica.


→ Filtrado y limpieza de la nube de puntos

Antes de identificar activos, la nube de puntos se somete a procesos de depuración (Figura 4), que incluyen:

- Eliminación de ruido (puntos erráticos fuera de rango).
- Reducción de duplicados o solapamientos innecesarios.
- Clasificación preliminar de puntos en terreno, vegetación e infraestructuras.

Esta clasificación inicial se apoya en algoritmos que consideran la altitud relativa, curvatura, reflectancia y densidad local de puntos.

Figura Nro. 2.4: Nube de puntos del alimentador 42A



→ Marcado e identificación de elementos eléctricos

Una vez depurada, la nube de puntos se procesa para la identificación sistemática de los activos eléctricos. Este procedimiento se realiza mediante el software Potree, iniciando con la detección de postes o estructuras de soporte. Sobre cada uno se coloca un punto de referencia tridimensional, que posteriormente se transforma en una entidad vectorial con atributos espaciales y técnicos.

El uso de Potree agiliza significativamente la identificación y vinculación de elementos, ofreciendo una plataforma intuitiva para gestionar grandes volúmenes de datos LiDAR sin comprometer la precisión en la caracterización de los activos eléctricos y sus interconexiones (Figura 5).

A partir de los postes marcados, se ejecuta una segunda fase de identificación que vincula:

- Postes con transformadores
- Semáforos
- Tensores
- Cámaras
- Fachadas

Figura Nro. 2.5: Marcado de activos eléctricos



→ Edición

La fase de edición incorpora información eléctrica específica mediante una caracterización precisa de la red. Este proceso integral comienza con la identificación de fases y secuencia, utilizando equipos SPI-III para determinar la configuración trifásica en cada punto de conexión (Figura 6). Simultáneamente, se realiza la georreferenciación de medidores y puntos de carga, ubicando espacialmente cada punto de consumo y vinculándolo con su transformador correspondiente.

El procedimiento se complementa con una actualización masiva de atributos técnicos, que incluye: redes de distribución de media y baja tensión, transformadores, seccionadores, protecciones (en baja tensión y dinámicas), así como elementos de red como luminarias, semáforos, pararrayos y cámaras de vigilancia.

Figura Nro. 2.6: Identificación de fases y conductores SPI-III.



2.2.6 Digitalización del Levantamiento en Campo

Como parte del proceso de ejecución del levantamiento, se implementó un sistema de captura digital de información, mediante formularios estructurados en la plataforma Survey (Figura 7).

Esta herramienta permitió una recolección estandarizada, georreferenciada y en tiempo real de los elementos de la red eléctrica, consolidando una base de datos homogénea, trazable y de alta precisión.

Cada formulario incorporó lógicas condicionales, validaciones automáticas y campos obligatorios para garantizar la consistencia de los datos y minimizar errores en el registro. Entre los principales campos se incluyeron:

- Tipo de activo (poste, transformador, seccionador, etc.)
- Identificador único
- Coordenadas geográficas (captura automática por GPS)
- Fotografía del activo
- Estado operativo
- Observaciones técnicas

Figura Nro. 2.7: Base de Datos Corporativa

2.3 Magnitud del desafío

La complejidad del proyecto se evaluó mediante un análisis multidimensional que abarcó desafíos geográficos, técnicos, de gestión de datos y operativos. Este apartado describe estas dimensiones críticas, destacando la integración de tecnologías de captura multimodal y la transformación de grandes volúmenes de datos en un modelo inteligente y accionable para la gestión de activos.

2.3.1 Dimensión Geográfica y de Escala

La topografía del Distrito Metropolitano de Quito y sus alrededores, con más de 50 km de extensión longitudinal en un valle interandino, presenta desniveles pronunciados, laderas empinadas y quebradas profundas. Estas condiciones incrementaron la complejidad logística y los riesgos en la adquisición de datos. A esto se sumó el reto de garantizar una cobertura homogénea y precisa tanto el centro urbano denso como las áreas rurales y suburbanas adyacentes, donde la red se extiende por zonas remotas y de difícil acceso.

2.3.2 Desafío técnico y de precisión

La red eléctrica constituye una infraestructura crítica de alta complejidad sistémica, cuya densidad y diversidad de activos trasciende la simple integración de postes y cables. Capturar la geometría 3D de cada elemento con exactitud representó un desafío significativo. El núcleo del reto radicó en la integración multimodal, no bastaba con realizar levantamientos aéreos y terrestres por separado, sino fusionarlos en un modelo coherente y unificado.

2.3.3 Desafío de gestión de datos

Los levantamientos LiDAR generaron volúmenes masivos de datos (Big Data), alcanzando terabytes de información

en forma de nubes de puntos. Esto exigió infraestructura tecnológica especializada, workstations de alto rendimiento, software avanzado para clasificación y análisis, y unidades de almacenamiento NAS de gran capacidad para garantizar accesibilidad, seguridad y respaldo. Transformar estos datos en información accionable (Smart Data) requirió el desarrollo de plataformas y metodologías integradas que combinaron todos los métodos de recolección y facilitaron el acceso del equipo técnico.

Además, el entorno dinámico y hostil, con vegetación que oculta activos, interferencias visuales por tráfico y actividad humana, demandó técnicas avanzadas de filtrado, fusión de datos y planificación logística minuciosa para superar estas limitaciones mediante tecnologías complementarias.

2.3.4 Desafío operacional y de gobernanza

Uno de los mayores retos fue la gestión logística y de seguridad, coordinar sobrevuelos, movilizar equipos terrestres y proteger al personal en vías públicas y áreas de alto riesgo eléctrico. Paralelamente, se asumió un cambio cultural profundo: pasar de planos 2D a un modelo digital unificado y preciso. Para lograrlo, fue indispensable invertir en capacitación técnica, adaptar procedimientos y asegurar la adopción de estas herramientas en todos los niveles de la organización.

La magnitud del desafío tuvo una naturaleza geométrica, resultado de la integración de dimensiones técnicas, logísticas y humanas. Superarlo no dependió únicamente de adquirir tecnología LiDAR, sino de ejecutar un proyecto de ingeniería de sistemas con visión holística, planificación meticulosa y una sólida gestión del cambio.

2.4 Resultados

La ejecución del proyecto permitió desarrollar un modelo geoespacial de alta fidelidad, en el que la precisión y la densidad de puntos obtenidos del sistema LiDAR móvil fueron factores determinantes para el levantamiento integral de los 20,328 km de red eléctrica. Este logro consolida un gemelo digital notable, caracterizado por su amplia cobertura y elevado nivel de detalle geométrico.

El levantamiento LiDAR multimodal alcanzó una cobertura total del 100% de la red de distribución. El inventario geoespacial generado (Tabla 3) se constituye como un activo de información sin precedentes para el sector eléctrico ecuatoriano.

Tabla Nro. 2.3: Métricas de cobertura e inventario de activos.

Parámetro	Valor
Subestaciones primarias	209
Subestaciones secundarias	21
Red de Baja Tensión Aérea (BTA)	8 809 km
Red de Baja Tensión Subterránea (BTS)	2 244 km
Red de Media Tensión Aérea (MTA)	8 591 km
Red de Media Tensión Subterránea (MTS)	684 km
Transformadores de distribución	43 586
Luminarias	297 155
Semáforos y cámaras	6 851
Medidores	780 000
Clientes en el ámbito de influencia	1 245 542

La implementación del sistema ha generado mejoras significativas en los principales indicadores de gestión:

- Reducción de pérdidas de energía, gracias a la identificación precisa de puntos críticos y la optimización del flujo energético, lo que impacta

Reducción de pérdidas de energía, gracias a la identificación precisa de puntos críticos y la optimización del flujo energético, lo que impacta

→ directamente en la disminución de costos operativos.

Disminución del tiempo de respuesta ante fallas, mediante diagnósticos en tiempo real que permiten acciones inmediatas. Actualmente la EEQ logra

→ restablecer el servicio en menos de tres horas en el 98% de los casos.

Incremento en los ingresos por facturación, resultado de la eliminación de inconsistencias y la optimización de procesos de recaudación,

→ incluyendo la actualización de más de 166,000 registros del catastro de clientes.

Optimización de recursos humanos y técnicos, con menor necesidad de visitas en campo y

2.5 Conclusiones

Este proyecto se consolida como un pilar estratégico para la modernización del sector eléctrico nacional, alineado con los objetivos del Plan Maestro de Electricidad (PME) en cuatro dimensiones clave:

1. Confiabilidad del servicio, mediante simulaciones predictivas que anticipan fallas y optimizan el mantenimiento.
2. Transición energética segura, actuando como un banco de pruebas virtual para integrar energías renovables sin comprometer la estabilidad de la red.
3. Eficiencia en inversiones, priorizando recursos en

proyectos críticos a partir de análisis técnicos basados en datos.

4. Modernización tecnológica, estableciendo las bases para redes inteligentes mediante una plataforma digital interoperable.

El gemelo digital transforma activos, pasando de un enfoque reactivo a uno proactivo y predictivo, fortaleciendo la resiliencia de la red frente a fenómenos naturales mediante análisis de riesgo geoespacial.

Además, el proyecto trasciende su utilidad operativa al crear un estándar nacional de datos geoespaciales, constituyendo un bien público digital que impulsa la innovación y sienta las bases para una red eléctrica inteligente y resiliente en todo el país. No se trata únicamente de tecnología, sino de una inversión estratégica en el futuro energético de Ecuador.

Como perspectiva de desarrollo, la metodología demostró ser escalable y replicable para entornos topográficamente complejos, abriendo el camino a futuros proyectos que incorporen algoritmos de inteligencia artificial para automatizar procesos de clasificación, mejorar la precisión y adaptar la técnica a diferentes contextos geográficos nacionales y regionales.

Bibliografía

- [1] Yermo, M., Martínez, J. & Lorenzo, O. G. (2019, 1 January). Automatic detection and characterisation of power lines and their surroundings using lidar data. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLII-2/W13, 1161-1168. <https://doi.org/10.5194/isprs-archives-XLII-2-W13-1161-2019>
- [2] Manzano Mantilla, M. J. (2022). Situación actual del sector eléctrico ecuatoriano y sus desafíos. In Marco Aurelio Romero Cevallos, Maestría En Relaciones Internacionales. Universidad Andina Simón Bolívar. <https://repositorio.uasb.edu.ec/bitstream/10644/9043/1/T3958-MRI-Manzano-Situacion.pdf>.
- [3] Chasco Hernández, D. (2018). Detección automática de líneas eléctricas de alta tensión en datos LiDAR mediante minería de datos [Thesis, Universidad Pública de Navarra]. <https://academica-e.unavarra.es/server/api/core/bitstreams/bddbe63c-2d26-4e13-bf81-6734a8c40a7e/content>
- [4] Bugalski de Andrade, E., & Da Silva, J. A. (2024, 1 diciembre). RPAS and LIDAR Technologies: an alternative for monitoring power line. IOSR Journal Of Applied Geology And Geophysic. <https://doi.org/10.9790/0990-1206012027>.
- [5] Cheng, L., Chen, S., Liu, X., Xu, H., Wu, Y., Li, M., & Yanming Chen. (2018). Registration of Laser Scanning Point Clouds: A Review. En Sensors. <https://www.mdpi.com/journal/sensors>
- [6] Wulder, M. A., Bater, C. W., Coops, N. C., Hilker, T., & White, J. C. (2008). The role of LiDAR in sustainable forest management. The Forestry Chronicle, 84(6), 807.

Capítulo
03

Cifras del sector eléctrico ecuatoriano

Capítulo 03

Cifras del sector eléctrico ecuatoriano



Andrea Torres
Magíster en Energías Renovables

Christian Junia
Ingeniero Eléctrico

Óscar Salazar
Ingeniero Eléctrico

Al cierre de noviembre de 2025, el sistema eléctrico ecuatoriano presenta una infraestructura y un desempeño operativo que se sintetizan en tres bloques:

3.1 Generación y transmisión

La generación eléctrica bruta a nivel nacional, considerando el Sistema Nacional Interconectado (S.N.I.) y los Sistemas No Incorporados, alcanzó 37.670 GWh, respaldada por una capacidad instalada nacional de 9.442 MW y una potencia efectiva de 8.819 MW. Respecto al S.N.I., la energía bruta generada alcanzó los 33.424 GWh, con una capacidad instalada de 8.892 MW y una potencia efectiva de 7.729 MW.

El Sistema Nacional de Transmisión se compone de 6.696 km de líneas y 61 subestaciones que en conjunto suman 16.203 MVA de capacidad de transformación. Durante el periodo se registraron importaciones netas de 694 GWh y exportaciones de 191 GWh.

3.2 Distribución y comercialización

La red de distribución opera con 387.409 transformadores de media tensión y 113.473 km de redes secundarias, alimentando 2.102.355 luminarias y 5.798.413 medidores en servicio. La demanda regulada se situó en 24.816 GWh, mientras que el mercado no regulado sumó 1.869 GWh. Las pérdidas totales de energía eléctrica en distribución ascendieron a 5.122 GWh (15,94 %), desagregadas en pérdidas técnicas (1.899 GWh, 5,91 %) y no técnicas (3.223 GWh, 10,03 %).

3.3 Talento humano del sector

El sector eléctrico emplea a 16.641 personas, distribuidas principalmente en las empresas de distribución (11.153), generación (3.734), transmisión (729) y autogeneración (1.025). Este capital humano resulta fundamental para garantizar la continuidad, la seguridad y la calidad del servicio a escala nacional.

Las Figuras 3.1, 3.2 y 3.3 resumen visualmente estos indicadores, proporcionando una vista comparativa e integrada de la realidad operativa del sector eléctrico ecuatoriano.

Figura Nro. 3.1: Cifras principales del sector eléctrico






Figura Nro. 3.2: Potencia, producción de energía, consumos, facturación



Se presenta información de demanda de potencia anual, mensual y diaria. Además, la demanda no coincidente de las distribuidoras con mayor participación en el mes de noviembre 2025.

Figura Nro. 3.3: Demanda de Energía en el Sistema Nacional Interconectado



3.4 Cifras de generación

Empresas de Generación, Autogeneración, Distribución y SGDAs

Potencia Efectiva (MW)

Noviembre 2025

Figura Nro. 3.4: Generadoras




Figura Nro. 3.5: Autogeneradoras




Figura Nro. 3.6: Distribuidoras





Figura Nro. 3.7: Sistemas de generación para autoabastecimiento - SGDA's instalados en área de concesión de las Empresas Eléctricas de Distribución



3.5 Cifras de transmisión

CELEC EP TRANSELECTRIC

Noviembre 2025

Tabla Nro. 3.1: Líneas de Transmisión Sistema Nacional Interconectado (S.N.I.)

Tipo	Nivel de voltaje (kV)	Número de líneas #	Longitud (km)
Simple Circuito	138	39	1.868,19
	230	22	1.592,08
	500	6	610,00
Total Simple Circuito		67	4.070,27
Doble Circuito	138	15	530,38
	230	28	2.094,92
Total Doble Circuito		43	2.625,30
Total General		110	6.695,57

* Incluyen líneas de interconexión con Colombia y Perú

Tabla Nro. 3.2: Líneas de Transmisión de Interconexión

Tipo	Nivel de voltaje (kV)	Nombre Línea	Longitud Total (km)
Simple Circuito	138	Tulcán - Panamericana	15,50
Total Simple Circuito			15,50
Doble Circuito	230	Machala - La Avanzada	31,00
		La Avanzada - Alipio Rosales	53,20
		Pimampiro - Jamondino 1	138,70
		Pimampiro - Jamondino 2	132,00
Total Doble Circuito			354,90

Tabla Nro. 3.3: Subestaciones y transformadores del Sistema Nacional Interconectado (S.N.I.)

Tipo de Subestación	Número de Subestaciones	Número de Transformadores	Capacidad Máxima (MVA)
Reducción	57	93	16.008,28
Móviles - reducción	4	4	195,00
Total	61	97	16.203,28

3.6 Cifras de distribución y comercialización

Empresas de distribución y comercialización

Noviembre 2025

Tabla Nro. 3.4: Infraestructura de Distribución

Empresa	 Media tensión	 Transformadores		 Baja tensión	 Luminarias		 Medidores
	km	#	MVA	km	#	kW	#
CNEL-Bolívar	3.497,57	6.974	105,29	3.790,03	30.032	4.942,77	74.080
CNEL-El Oro	6.021,82	17.126	792,26	4.096,46	110.053	20.587,17	286.138
CNEL-Esmeraldas	5.184,11	11.403	367,59	3.214,59	62.848	11.536,46	131.885
CNEL-Guayaquil	4.049,71	42.116	2.792,09	6.169,64	209.642	34.496,04	720.394
CNEL-Guayas Los Ríos	9.239,73	37.061	1.517,49	6.217,52	120.174	21.868,14	377.625
CNEL-Los Ríos	3.848,35	11.597	381,84	2.404,51	40.288	7.256,22	153.623
CNEL-Manabí	8.973,82	32.925	1.054,29	7.920,86	154.161	27.495,75	366.664
CNEL-Milagro	4.667,51	14.354	482,07	2.387,94	59.258	11.361,41	167.928
CNEL-Sta. Elena	1.669,13	8.862	416,19	1.692,57	48.563	9.627,59	109.066
CNEL-Sto. Domingo	10.602,86	26.249	558,78	7.047,37	96.131	17.044,01	283.654
CNEL-Sucumbios	5.696,50	11.868	320,46	4.979,35	57.604	8.972,69	116.192
E.E. Ambato	6.474,17	18.283	509,28	9.271,54	168.763	25.028,91	314.256
E.E. Azogues	892,61	2.416	73,60	1.593,47	20.446	3.501,34	42.274
E.E. Centro Sur	11.215,16	30.222	992,75	13.910,05	191.346	34.837,20	456.880
E.E. Cotopaxi	4.754,06	11.670	358,70	6.642,50	76.043	11.017,64	161.966
E.E. Galápagos	375,61	1.372	48,40	279,90	6.929	820,03	15.223
E.E. Norte	6.789,67	20.556	593,87	7.868,80	139.238	20.474,75	286.371
E.E. Quito	9.465,26	44.840	3.147,20	11.938,26	335.905	53.929,47	1.300.067
E.E. Riobamba	4.726,85	16.010	332,28	5.969,13	90.928	12.195,68	194.787
E.E. Sur	9.091,92	21.505	428,36	6.078,90	84.003	10.511,62	239.340
Total	117.236,40	387.409	15.272,80	113.473,39	2.102.355	347.504,88	5.798.413

Tabla Nro. 3.5: Tipo de Consumidores por Empresa Eléctrica de Distribución

Empresa	Consumidores regulados				 Total regulados	 Total no regulados	 Total
	Residencial	Comercial	Industrial	Otros			
CNEL-Bolívar	68.763	3.754	103	1.469	74.089	-	74.089
CNEL-EI Oro	261.616	18.129	1.450	3.759	284.954	1	284.955
CNEL-Esmeraldas	121.748	7.318	293	2.440	131.799	2	131.801
CNEL-Guayaquil	640.473	72.405	1.996	5.533	720.407	50	720.457
CNEL-Guayas Los Ríos	350.042	20.738	777	6.104	377.661	16	377.677
CNEL-Los Ríos	143.463	7.879	313	1.972	153.627	1	153.628
CNEL-Manabí	341.787	18.980	470	5.433	366.670	8	366.678
CNEL-Milagro	153.332	11.677	179	1.744	166.932	6	166.938
CNEL-Sta. Elena	99.317	6.285	157	1.749	107.508	2	107.510
CNEL-Sto. Domingo	252.622	27.320	288	3.444	283.674	4	283.678
CNEL-Sucumbíos	100.747	12.537	430	2.522	116.236	-	116.236
E.E. Ambato	272.333	30.719	5.837	5.463	314.352	6	314.358
E.E. Azogues	38.486	2.849	415	620	42.370	1	42.371
E.E. Centro Sur	409.356	39.245	4.630	7.182	460.413	2	460.415
E.E. Cotopaxi	143.936	12.706	3.101	2.292	162.035	3	162.038
E.E. Galápagos	12.066	2.389	184	599	15.238	-	15.238
E.E. Norte	250.014	29.616	2.564	3.616	285.810	6	285.816
E.E. Quito	1.122.442	147.572	11.662	19.287	1.300.963	160	1.301.123
E.E. Riobamba	170.885	19.961	630	3.350	194.826	1	194.827
E.E. Sur	211.021	20.337	1.148	7.050	239.556	-	239.556
Total	5.164.449	512.416	36.627	85.628	5.799.120	269	5.799.389



Agencia de Regulación y Control
de Electricidad



@arconel



@arconel_ec



@ARCONEL_Ec

www.arconel.gob.ec