

# Identificación de anomalías en el aislamiento de líneas de transmisión a partir de imágenes

–Maestría en Ciencias de los Datos y Analítica–

Escuela de Ciencias Aplicadas e Ingeniería  
Universidad EAFIT

Proyecto desarrollado por

Daniel Alonso Sánchez Echeverri  
[dasancheze@eafit.edu.co](mailto:dasancheze@eafit.edu.co)

15 de abril de 2024

Directores de proyecto

1: Juan David Martínez Vargas  
[jdmartinev@eafit.edu.co](mailto:jdmartinev@eafit.edu.co)

2: Edison Valencia Díaz  
[evalenci@eafit.edu.co](mailto:evalenci@eafit.edu.co)

# Índice

<b>Resumen</b>	<b>1</b>
<b>1. Descripción del problema</b>	<b>2</b>
1.1. Planteamiento del problema . . . . .	2
1.2. Justificación . . . . .	4
<b>2. Objetivos</b>	<b>4</b>
2.1. Objetivo general . . . . .	4
2.2. Objetivos específicos . . . . .	5
<b>3. Estado del arte y Marco teórico</b>	<b>5</b>
3.1. Sistema Eléctrico de Potencia - SEP . . . . .	5
3.2. Drones en inspección de Sistemas Eléctricos de Potencia - SEP . . . . .	7
3.3. Imágenes digitales . . . . .	7
3.4. Visión artificial . . . . .	8
3.5. Detección de objetos en imágenes . . . . .	9
3.6. Segmentación de imágenes . . . . .	12
3.7. Clasificación de imágenes . . . . .	13
<b>4. Desarrollo metodológico CRISP - DM</b>	<b>14</b>
4.1. Entendimiento del negocio . . . . .	15
4.2. Entendimiento de los datos . . . . .	16
4.3. Preparación de los datos . . . . .	17
4.4. Modelado . . . . .	19
4.5. Evaluación . . . . .	25
4.6. Despliegue . . . . .	26
<b>5. Resultados obtenidos</b>	<b>27</b>
<b>6. Conclusiones</b>	<b>30</b>
<b>Referencias</b>	<b>31</b>

## **Resumen**

En la actualidad, el mantenimiento de las líneas de transmisión de energía eléctrica se basa en tareas de inspección que requieren largos recorridos por terrenos complejos para determinar la condición de esta infraestructura. Los avances tecnológicos en vehículos aéreos no tripulados, también conocidos como drones, han permitido que algunas tareas de inspección se realicen de manera remota, capturando fotografías de la infraestructura. Posteriormente, se analizan estas imágenes para identificar el estado físico de los activos. Sin embargo, el procesamiento y visualización constituyen un procedimiento manual que demanda horas de revisión para identificar los problemas.

En este contexto, el presente trabajo propone el uso de algoritmos de visión artificial, con el fin de identificar los elementos de la red que presentan anomalías, afectando el normal funcionamiento del sistema de transmisión de energía eléctrica. Con esta estrategia, se espera mejorar la eficiencia en la identificación de problemas en la infraestructura de energía eléctrica, reduciendo el tiempo y los costos asociados a la revisión manual de las imágenes obtenidas por los drones.

El conjunto de datos ha sido obtenido de una empresa del sector de energía eléctrica en Colombia. En este documento, por razones de protección de datos y ética empresarial, la empresa ha sido anonimizada y renombrada como Empresa de Energía EE.

# 1. Descripción del problema

## 1.1. Planteamiento del problema

La energía eléctrica es fundamental para el desarrollo de la sociedad y la economía actual. Normalmente las grandes ciudades y los sitios de consumo, están alejados de centrales y puntos de generación de energía eléctrica, por lo cual es necesario contar con robustos sistemas de transmisión de energía eléctrica a altos voltajes, que permitan mantener conectada la generación con los puntos de consumo.

Las líneas aéreas de transmisión de energía se convierten en el principal medio de transporte de energía. Sin embargo, las torres de transmisión de energía de alto voltaje como una parte importante de las líneas de transmisión, están expuestas al entorno, por la erosión del viento, junto con la tensión mecánica continua y los efectos del envejecimiento del material, lo que ocasiona una variedad de daños, como la oxidación de la torre, el agrietamiento y otras condiciones. Si estas situaciones peligrosas no se pueden abordar de manera oportuna, los pequeños daños pueden expandirse y provocar la interrupción de la transmisión de energía eléctrica, lo que resulta en enormes pérdidas económicas [1]. Por lo tanto, es necesario que la línea de transmisión aérea de la torre de energía se mantenga e inspeccione regularmente.

Los aisladores eléctricos son componentes esenciales en un sistema de transmisión de energía eléctrica porque ayudan a prevenir el flujo de corriente no deseado entre las líneas de transmisión y la estructura de soporte, lo que podría causar daños o cortocircuitos en el sistema. Los aisladores se utilizan para separar eléctricamente las líneas de transmisión de los postes, torres u otras estructuras de soporte de las líneas eléctricas. Estos componentes están diseñados para soportar cargas mecánicas y ambientales, como la lluvia, el viento y la contaminación, para evitar que la corriente fluya a través de la estructura y cause daños o interrupciones en el suministro de energía eléctrica. Los aisladores pueden acumular suciedad, contaminación y otros depósitos a lo largo del tiempo, lo que puede disminuir su capacidad para aislar eléctricamente las líneas de transmisión de la estructura de soporte. Además, los aisladores también pueden sufrir daños físicos debido a impactos de objetos externos, el desgaste por vibraciones y tensiones mecánicas. El mantenimiento de los aisladores puede incluir la limpieza de la superficie para eliminar la suciedad y la contaminación, así como la inspección visual para detectar cualquier daño o fisura en la superficie. Si se detectan daños o fisuras, se debe realizar la reparación o el re-

emplazo del aislador para garantizar que el sistema de transmisión siga funcionando de manera segura y confiable. [2] [3]

Es por esto que para mantener un sistema de transmisión de energía operando en óptimas condiciones, requiere que se desarrollen diversas actividades de mantenimiento, entre las cuales se destacan las inspecciones visuales que buscan detectar posibles anomalías en la infraestructura que deben ser reparadas con el fin de garantizar la continuidad del servicio de energía eléctrica. Históricamente las inspecciones de las líneas de transmisión se han desarrollado mediante caminatas en el recorrido de estas líneas, observando en cada punto la condición de la infraestructura, para que posteriormente sean programados los trabajos de reparación o cambio de los elementos que se encuentren deteriorados. Esta forma de trabajo requiere largos recorridos por lugares de difícil acceso para capturar la información necesaria, realizar el análisis de los datos de las inspecciones y tomar las decisiones sobre la infraestructura, lo que implica que una inversión significativa de tiempo entre los recorridos y las actividades de reparación. [4]

El desarrollo de nuevas tecnologías ha permitido facilitar algunas tareas de inspección en las redes. Mediante el uso de Vehículos Aéreos No Tripulados (Drones) se posibilita la captura de información en lugares de difícil acceso, logrando obtener imágenes cercanas a la infraestructura con el fin de lograr diagnósticos más detallados [5]. Esto puede proporcionar una solución más rápida, precisa y segura para la detección de problemas en el aislamiento. Los drones pueden equiparse con cámaras de alta resolución y sensores especializados, que permiten capturar imágenes de alta calidad de las líneas de transmisión y los aisladores desde diferentes ángulos y perspectivas. [6]

Esta nueva forma de realizar inspección a las líneas de transmisión eléctrica implica resolver retos en cuanto al manejo de información generada. Uno de los desafíos fundamentales está en el volumen de los datos, debido a que en este proceso se pueden generar grandes cantidades de datos con imágenes de alta resolución, videos, datos geoespaciales, etc., los cuales se convierten en un insumo para que los responsables del mantenimiento de estas líneas puedan detectar las anomalías y priorizar la atención de los problemas identificados.

Este procesamiento de información se hace de manera manual, requiriendo gran cantidad de horas hombre para la identificación de anomalías. Es por esto que en el presente trabajo se propone la utilización de algoritmos de Machine Learning para la detección de objetos, con el fin de facilitar el procesamiento de la información,

automatizar el proceso de identificación de objetos y anomalías, y facilitar la toma de decisiones, buscando una mejora en la eficiencia y reducción en los costos del proceso.

## **1.2. Justificación**

La implementación de tecnología de drones para inspeccionar líneas de transmisión de energía eléctrica introduce nuevas capacidades a la forma en que se lleva a cabo el mantenimiento e inspección de estas infraestructuras críticas. Sin embargo, el procesamiento manual de grandes cantidades de imágenes es un proceso largo que puede llevar a errores humanos y retrasar la toma de decisiones.

La utilización de técnicas de Machine Learning y visión artificial para la detección de objetos y anomalías en las imágenes de inspección de líneas de transmisión eléctrica puede ser una solución eficiente y efectiva, así como una forma de reducir los costos asociados con el mantenimiento de estas infraestructuras. Además, esta técnica puede ayudar a detectar anomalías y problemas de manera temprana, lo que puede mejorar la seguridad y evitar futuras fallas en el sistema. En este sentido, la realización de este proyecto de grado en una empresa del sector eléctrico en Colombia es una contribución al desarrollo de nuevas herramientas y técnicas que permitan optimizar las inspecciones de las líneas de transmisión eléctrica, lo que a su vez puede mejorar la confiabilidad del sistema eléctrico en general.

## **2. Objetivos**

### **2.1. Objetivo general**

Implementar algoritmos de visión artificial en imágenes de inspección de líneas de transmisión de energía eléctrica obtenidas con drones, con el fin de mejorar la eficiencia y precisión en la detección de posibles anomalías en el aislamiento de las líneas de transmisión, contribuyendo a la seguridad y el desempeño del sistema de transmisión.

## 2.2. Objetivos específicos

- Recopilar imágenes de inspección de líneas de transmisión de energía eléctrica obtenidas con drones y establecer una base de datos con imágenes etiquetadas según la condición del aislamiento eléctrico.
- Implementar un algoritmo de detección de objetos que permita identificar los aisladores que deben ser analizados en búsqueda de anomalías.
- Implementar un algoritmo de segmentación de imágenes con el fin de segmentar los platos de aislamiento, eliminando elementos que no son de interés del análisis de las imágenes.
- Implementar un algoritmo de clasificación de imágenes que permita identificar los platos de aislamiento que presentan anomalías y los que se encuentran en buena condición.
- Diseñar un pipeline que articule los algoritmos de identificación de objetos, segmentación y clasificación de imágenes, realizando pruebas y comparando los resultados con la detección manual de anomalías en el aislamiento eléctrico.

## 3. Estado del arte y Marco teórico

### 3.1. Sistema Eléctrico de Potencia - SEP

Un Sistema Eléctrico de Potencia (SEP) es un conjunto de componentes eléctricos, mecánicos y de control, diseñados para generar, transmitir y distribuir energía eléctrica a los consumidores finales. La generación de energía eléctrica se lleva a cabo en centrales eléctricas que convierten diversas fuentes de energía primaria en energía eléctrica, que luego se transmite a través de líneas de transmisión de energía eléctrica para distribuirse a los usuarios finales. [7]

Las líneas de transmisión de energía eléctrica son un activo clave de los sistemas eléctricos de potencia. Estas líneas transportan grandes cantidades de energía eléctrica a largas distancias, desde las centrales eléctricas hasta las subestaciones de distribución.

Los componentes eléctricos de las líneas de transmisión incluyen los conductores, que son generalmente de aluminio o cobre y se utilizan para transportar la energía

eléctrica a larga distancia, y los aisladores, que se utilizan para soportar los conductores eléctricos y aislarlos eléctricamente de los soportes mecánicos y la tierra. Los componentes mecánicos de las líneas de transmisión incluyen las torres, que sostienen los conductores a lo largo de la línea y proporcionan soporte mecánico, y los soportes, que se utilizan para unir los aisladores y los conductores a las torres.

El aislador es un componente clave en las líneas de transmisión de energía eléctrica. Su función principal es soportar los conductores eléctricos y aislarlos eléctricamente del soporte mecánico y la tierra. Los aisladores se utilizan para prevenir la fuga de corriente eléctrica desde el conductor hacia la torre de soporte y garantizar la seguridad de las personas y los equipos. [7]

Los aisladores pueden estar fabricados de diferentes materiales dieléctricos, como porcelana, vidrio, polímeros o cerámica. Estos deben ser capaces de soportar las condiciones ambientales extremas, como la lluvia, el viento, la nieve y la contaminación, sin comprometer su capacidad de aislamiento eléctrico. Además, los aisladores deben ser diseñados para soportar cargas mecánicas y térmicas que pueden generarse durante la operación de la línea de transmisión. [8]

Los posibles modos de falla que pueden presentar los aisladores incluyen el envejecimiento y la degradación del material dieléctrico, la contaminación, la vibración mecánica, la rotura de los soportes mecánicos, la formación de arcos eléctricos y la sobrecarga eléctrica. Estas fallas pueden reducir la capacidad de aislamiento eléctrico de los aisladores, aumentar el riesgo de accidentes eléctricos y afectar la calidad y confiabilidad de la transmisión de energía eléctrica. [7]

Así, los aisladores son un componente crítico en las líneas de transmisión de energía eléctrica, ya que garantizan la seguridad y confiabilidad del sistema eléctrico. Es necesario prestar atención a su diseño, fabricación y mantenimiento para asegurar su correcto funcionamiento y evitar posibles fallas.

En la industria energética se han empezado a usar los drones como una herramienta valiosa para la inspección de líneas de transmisión de energía eléctrica, ya que permiten realizar inspecciones más seguras, eficientes y precisas que los métodos tradicionales. Los avances tecnológicos en los drones, como la mejora en la calidad de imagen y la duración de la batería, han contribuido a su creciente popularidad en la industria de la energía. [9]

### **3.2. Drones en inspección de Sistemas Eléctricos de Potencia - SEP**

Un dron, también conocido como vehículo aéreo no tripulado, es un dispositivo volador que puede ser controlado a distancia o seguir una trayectoria autónoma programada. En los últimos años, los drones han experimentado avances tecnológicos significativos, lo que los ha convertido en herramientas cada vez más populares en una amplia gama de industrias, incluyendo la energética. [5]

En la inspección de líneas de transmisión de energía eléctrica, los drones son particularmente útiles porque pueden sobrevolar áreas de difícil acceso y proporcionar imágenes detalladas de los componentes de las líneas. Algunas de las ventajas de los drones en la inspección de líneas de transmisión incluyen:

- Seguridad: los drones pueden realizar inspecciones sin exponer a los trabajadores a riesgos innecesarios, ya que pueden acceder a áreas peligrosas y proporcionar una visión clara de las condiciones en las líneas de transmisión sin tener que escalar las estructuras.
- Eficiencia: los drones pueden realizar inspecciones más rápidas y precisas que los métodos tradicionales, lo que puede reducir los costos y el tiempo necesario para realizar una inspección completa de las líneas de transmisión.
- Calidad de imagen: los drones pueden tomar imágenes de alta resolución y grabar video en tiempo real de las líneas de transmisión, lo que puede ayudar a identificar problemas en los componentes de las líneas de transmisión y permitir una toma de decisiones más informada sobre las reparaciones necesarias.

### **3.3. Imágenes digitales**

Las imágenes digitales son representaciones visuales de información en formato digital. Se componen de píxeles, que son pequeños puntos de color que juntos forman una imagen. Cada píxel está compuesto por tres componentes de color: rojo, verde y azul (RGB, por sus siglas en inglés), que se combinan en diferentes proporciones para crear una variedad de colores. Las imágenes digitales pueden ser capturadas por cámaras digitales o escaneadas desde fotografías en papel o diapositivas. [10]

En el contexto de la visión artificial, las imágenes digitales se utilizan como entrada para algoritmos de procesamiento de imágenes y aprendizaje automático. Estos

algoritmos pueden extraer características de las imágenes y utilizarlas para tareas como clasificación, detección de objetos, segmentación y reconocimiento facial. [11]

Las imágenes digitales se almacenan en formatos de archivo como JPEG, TIFF, GIF, BMP y PNG. Cada formato tiene sus propias ventajas y desventajas en términos de calidad de imagen, tamaño de archivo y compatibilidad con diferentes dispositivos y aplicaciones. A continuación se describen algunos de los formatos más comunes de las imágenes digitales:

**JPEG (Joint Photographic Experts Group):** Formato con compresión que causa pérdida de información. Soporta imágenes de 8 bits de escala de grises o imágenes de 24 bits RGB. [10]

**TIFF: (Tagged Image File Format):** Formato flexible con o sin compresión. Los tags aportan mucha flexibilidad. TIFF pueden almacenar información específica de espacios de color. Utilizados en sistemas GIS. [10]

**GIF: (Graphics Interchange Format):** Normalmente limitado a paletas de 8 bits. GIF es apropiado para guardar diagramas simples, logos e imágenes tipo caricatura. Utiliza compresión LZW. Soporta la capacidad de almacenar animaciones. [10]

**BMP: (Windows bitmap):** Formato de imágenes de Windows. No son comprimidos y por lo tanto tienen un gran tamaño. La ventaja es la simpleza del formato. [10]

**PNG: (Portable Network Graphics):** Alternativa libre a los GIF. Soporta paletas de colores y color verdadero de 24 o 48 bits (16 millones de colores). Los PNG soportan transparencias tal como los GIF. [10]

### 3.4. Visión artificial

La visión artificial es una rama de la inteligencia artificial que busca emular la capacidad del ser humano para procesar, interpretar y comprender imágenes y videos del mundo real. Esta disciplina se enfoca en desarrollar algoritmos y sistemas que permitan a las máquinas adquirir, analizar y comprender información visual, con el objetivo de que puedan tomar decisiones y realizar tareas que requieren conocimiento visual. [12]

Entre las aplicaciones más comunes de la visión artificial se encuentran la identificación de objetos, la detección de anomalías, el seguimiento de objetos en movimiento,

la clasificación de imágenes, la segmentación de objetos, la interpretación de escenas y la generación de modelos 3D. La visión artificial ha encontrado aplicaciones en diversas áreas, como la medicina, la robótica, la manufactura, la seguridad, el transporte, el entretenimiento, entre otras. [12]

Los componentes fundamentales de un sistema de visión artificial incluyen la adquisición de datos (cámaras o sensores), el procesamiento de imágenes (filtrado, segmentación, reconocimiento), la representación de datos (descriptores y características de imagen), el aprendizaje automático (aprendizaje supervisado, no supervisado, por refuerzo) y la toma de decisiones (clasificación, detección, seguimiento, predicción). [12]

### 3.5. Detección de objetos en imágenes

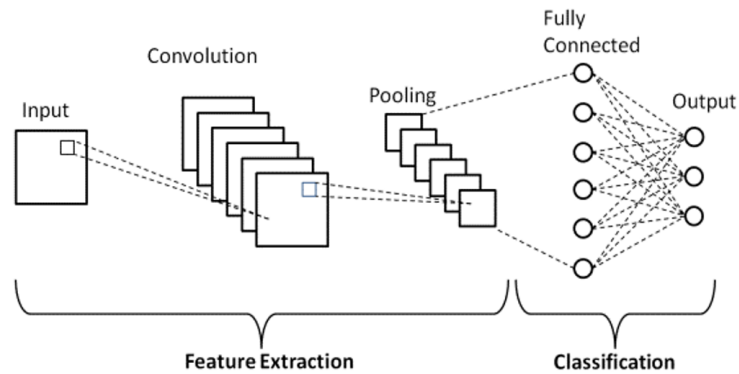
El problema de detección de objetos en visión artificial se refiere a la tarea de encontrar objetos específicos en una imagen o video y marcarlos o delimitarlos mediante un cuadro delimitador o bounding box. Este problema se aborda típicamente mediante el uso de algoritmos de aprendizaje automático, como redes neuronales convolucionales (CNN), que pueden identificar patrones en los datos de entrenamiento y utilizarlos para clasificar y localizar objetos en nuevas imágenes. [13]

La dificultad de este problema radica en que los objetos pueden variar en tamaño, orientación, posición y apariencia en diferentes imágenes, por lo que se requiere un alto grado de precisión y robustez en la detección. Además, la detección de objetos puede ser una tarea computacionalmente intensiva, especialmente cuando se trabaja con grandes conjuntos de datos o en tiempo real. Por lo tanto, la selección adecuada de algoritmos, parámetros y técnicas de preprocesamiento de imágenes es fundamental para lograr resultados precisos y eficientes. [13]

Existen diferentes técnicas y algoritmos para resolver el problema de detección de objetos en visión artificial. A continuación se da un detalle sobre las Redes Neuronales Convolucionales CNN y el algoritmo de detección de objetos YOLO, el cual fue utilizado en el desarrollo del presente proyecto.


- Redes neuronales convolucionales (CNN): [14] Es un tipo de red neuronal artificial diseñada especialmente para procesar datos con estructuras de matriz, como imágenes y videos. Está compuesta por múltiples capas, incluyendo capas de convolución, de pooling y fully connected. En la Figura 1 se puede observar la arquitectura de una CNN.

Figura 1: Arquitectura de una CNN



En la capa de convolución (Figura 2), la red aplica un conjunto de filtros para convolucionar la entrada, lo que implica un proceso de multiplicación matricial y suma ponderada. Luego, se aplica una función de activación no lineal a la salida de cada filtro para generar características de la imagen.

Figura 2: Capa Convolutiva de una CNN



La capa de pooling reduce la dimensionalidad de la imagen al aplicar una operación de agrupación en la que se selecciona el valor máximo (MAX Pooling - Figura 3) o promedio (Avg Pooling - Figura 4) en cada región de la imagen.

Figura 3: CNN Max Pooling






Figura 4: CNN Average Pooling



Las capas fully connected (Figura 5) combinan las características extraídas de la imagen para realizar la tarea de clasificación. Cada entrada está conectada a todas las neuronas y tendrá el mismo número de neuronas que de clases que pueda predecir, estas capas suelen encontrarse al final de las arquitecturas CNN.

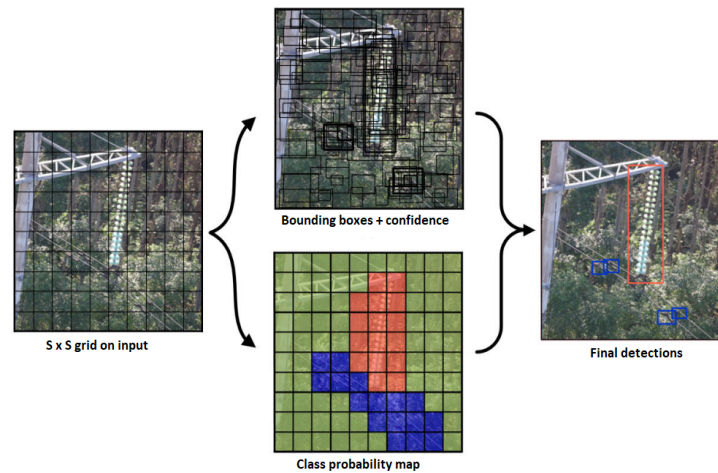
Figura 5: CNN Fully Connected Layer



- YOLO (You Only Look Once): [15] Este es uno de los algoritmos más populares para detección de objetos. Este algoritmo utiliza un enfoque totalmente diferente a los anteriores, esta red divide la imagen en regiones y predice cuadros delimitadores y probabilidades para cada región. La mayor diferencia ante otros algoritmos y lo que lo hace mucho más eficiente es que puede realizar predicciones con una sola evaluación de la red.

Su funcionamiento es el siguiente, se divide la imagen en una cuadrícula de dimensiones  $S \times S$ , dentro de cada cuadrícula se selecciona  $B$  cuadros delimitadores para cada uno de los cuales, la red genera una probabilidad de clase y valores de compensación para el cuadro delimitador. De entre los cuadros delimitadores establecidos se buscan aquellos cuya probabilidad de clase esté por encima de un valor umbral, estos son seleccionados y utilizados para localizar el objeto dentro de la imagen. Esto se muestra de manera gráfica en la Figura 6.

Figura 6: YOLO



### 3.6. Segmentación de imágenes

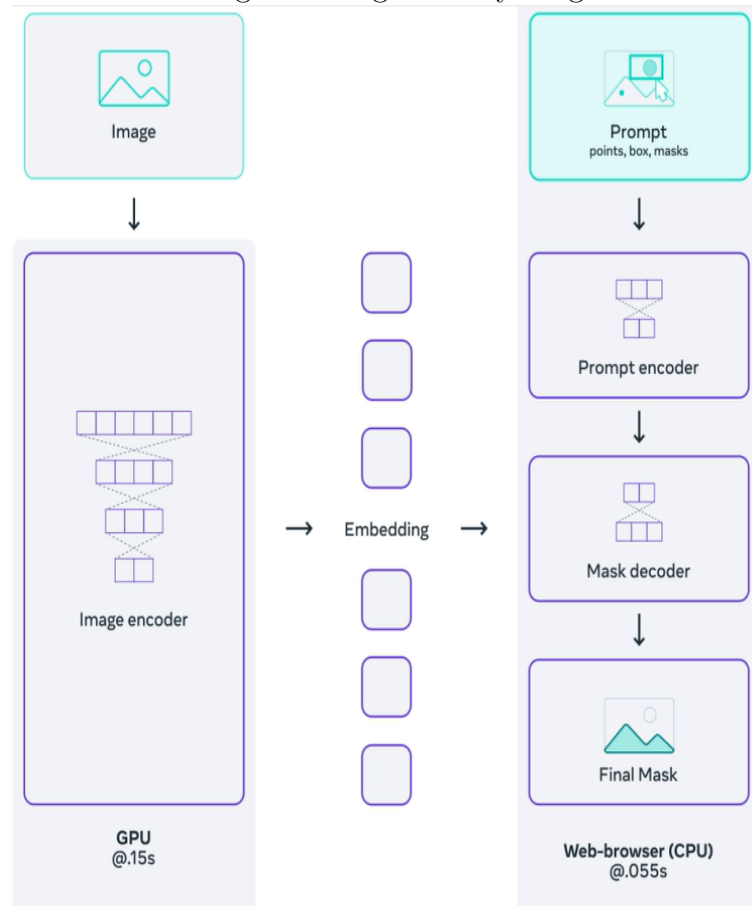
La segmentación de imágenes es una tarea en visión por computadora que consiste en dividir una imagen en regiones o segmentos, donde cada región representa un objeto, una característica o una región de interés. En otras palabras, la segmentación de imágenes permite identificar y etiquetar diferentes partes de una imagen en función de sus propiedades visuales, como el color, la textura, la forma, el contraste, entre otros. A continuación se realiza una breve descripción del algoritmo Segment Anything desarrollado por META, el cual fue utilizado durante el desarrollo del proyecto.

- Segment Anything (SA): [16] Modelo desarrollado por Meta AI, y es usado para la segmentación semántica de imágenes. A diferencia de los enfoques tradicionales que se centran en detectar objetos predefinidos, este modelo tiene la capacidad de segmentar cualquier cosa presente en una imagen, incluso clases no vistas durante el entrenamiento.

El modelo se basa en una arquitectura de red neuronal convolucional profunda que combina técnicas de aprendizaje supervisado y no supervisado. Durante el entrenamiento, se utilizan imágenes etiquetadas para aprender a segmentar objetos conocidos, mientras que también se aprovechan técnicas de agrupamiento y autoencoder para descubrir características latentes en las imágenes no etiquetadas. Esto permite que el modelo generalice y segmente objetos no

vistos anteriormente. La Figura 7 muestra el proceso realizado por el modelo Segment Anything partiendo desde la imagen de entrada hasta llegar a la generación de las mascarlas finales generadas a partir de un prompt.

Figura 7: SegmentAnything



### 3.7. Clasificación de imágenes

La clasificación de imágenes es una tarea fundamental en visión artificial y aprendizaje automático que consiste en asignar una etiqueta o categoría a una imagen dada. Este proceso implica que un algoritmo analice las características visuales de una imagen y la clasifique en una de varias clases predefinidas. Con el fin de identificar los elementos de aislamiento que presentan problemas y separarlos de lo que tienen una condición normal, se utilizó el algoritmo de clasificación de imágenes ResNet, el cual se describe a continuación:

- ResNet: [17]

ResNet (Redes Residuales) es un tipo de arquitectura de redes neuronales profundas que se destacó por su capacidad para entrenar redes aún más profundas y con un mejor rendimiento en tareas de clasificación de imágenes. La idea clave detrás de ResNet es la introducción de conexiones residuales o "skip connections" que saltan una o más capas. Estas conexiones permiten que la información fluya directamente a través de la red sin perderse en capas intermedias, lo que facilita el entrenamiento de redes extremadamente profundas. En lugar de aprender directamente la función deseada, ResNet aprende una función residual que es la diferencia entre la función deseada y la función de entrada. Esta diferencia se agrega de nuevo a la entrada original para obtener la salida final de la capa. Esta estructura residual permite que las redes sean más fáciles de optimizar durante el entrenamiento y evita el problema de desvanecimiento del gradiente que puede ocurrir en redes muy profundas. [18]

Es importante mencionar que las técnicas y algoritmos utilizados para la detección de objetos, segmentación y clasificación de imágenes están en constante evolución y mejora, y se basan en la combinación de modelos de redes neuronales convolucionales, técnicas de extracción de características, métodos de propuesta de regiones y técnicas de entrenamiento y optimización.

## **4. Desarrollo metodológico CRISP - DM**

El desarrollo del proyecto se realizó basado en la metodología CRISP-DM (Cross Industry Standard Process for Data Mining) (Figura 8) que es una metodología utilizada para guiar el proceso de resolución de problemas en proyectos de análisis de datos [19]. CRISP-DM proporciona un marco estructurado y sistemático que se divide en seis fases principales para llevar a cabo un proyecto de minería de datos.

Figura 8: Metodología CRISP-DM



Para el proyecto de identificación de anomalías en el aislamiento de líneas de transmisión a partir de imágenes, se desarrolló cada una de las fases de la metodología CRISP-DM. De cada fase se hará una breve descripción de lo realizado durante el desarrollo del presente proyecto.

#### 4.1. Entendimiento del negocio

El proyecto está enfocado en la necesidad del negocio de transmisión de energía eléctrica de una empresa del sector eléctrico colombiano, el cual tiene en su portafolio de activos líneas de transmisión de energía eléctrica. Dentro de las actividades de mantenimiento requeridas para esta infraestructura, se realizan inspecciones aéreas a las líneas de transmisión utilizando drones, tomando imágenes de su condición física. Estas imágenes son revisadas minuciosamente por expertos del proceso de mantenimiento con el fin de detectar anomalías en los elementos eléctricos de la red. La revisión manual de las imágenes implica alta inversión de tiempo de los expertos, que podría ser dedicado a otras actividades. Por esta razón este proyecto busca estar alineado con los objetivos del negocio de transmisión de energía eléctrica en cuanto a la optimización de los recursos y la mejora de la eficiencia operativa, con la premisa de garantizar la integridad de la infraestructura eléctrica.

Para la fase de entendimiento del negocio se realizaron reuniones con el personal experto en mantenimiento de líneas de transmisión, con el fin de comprender las

características del proceso y la forma en la cual las imágenes son tomadas y almacenadas para su revisión. En este punto se logra evidenciar la manualidad que requiere el proceso y la alta demanda de tiempo necesaria para generar los informes de inspección de las líneas. Adicionalmente, se identifica que las imágenes son usadas para determinar la condición de otros elementos que influyen en la confiabilidad de la red eléctrica, como lo son: terrenos donde están cimentadas las torres, vegetación cerca a las líneas, invasiones a la servidumbre, corrosión en estructuras y herrajes, pararrayos, conductores y conexiones de puesta a tierra.

Si bien el proyecto está enfocado en el caso de uso de identificación de anomalías en el aislamiento, en esta fase de entendimiento del negocio se logró establecer el potencial uso de algoritmos de visión artificial para identificar otros problemas asociados a los procesos de mantenimiento de la infraestructura eléctrica.

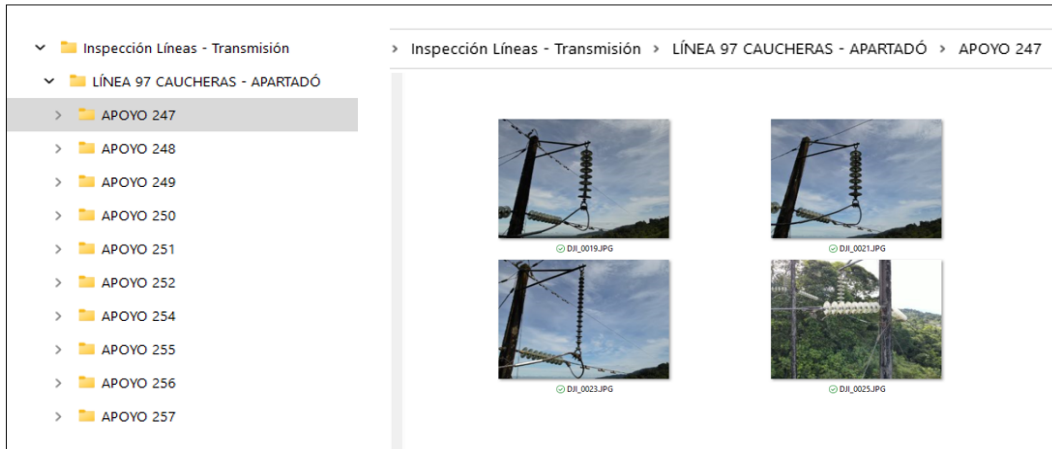
## **4.2. Entendimiento de los datos**

La fase de Entendimiento de los Datos se centró en comprender en detalle las imágenes capturadas durante el proceso de mantenimiento e inspección de líneas de transmisión de energía, que fueron adquiridas mediante el uso de drones. Estas imágenes se obtuvieron de cada una de las torres de transmisión con el propósito de servir como insumo fundamental para la identificación de posibles problemas en la red eléctrica. Se tomó información de 53 torres pertenecientes a una línea de transmisión ubicada en la región de Urabá, departamento de Antioquia, Colombia.

Durante esta fase, se exploraron aspectos clave de los datos, incluyendo el formato y la resolución de las imágenes, así como las condiciones de iluminación y el ángulo de captura. Se analizaron las características específicas de las torres, cables, aisladores y otros elementos presentes en las imágenes. A partir de esto se identificaron posibles desafíos, como la variabilidad en las condiciones climáticas y la presencia de objetos no deseados en las imágenes.

Asimismo, se consideró la estructura de almacenamiento de los datos. La estructura de los datos se basa en carpetas, donde cada carpeta se nombra de acuerdo al número de la torre de transmisión inspeccionada. Dentro de cada carpeta se encuentran los archivos de las imágenes tomadas durante el recorrido para ese apoyo específico. Este enfoque de organización de datos resultó crucial para facilitar la identificación y recuperación eficiente de las imágenes relacionadas con cada torre o apoyo durante las etapas de procesamiento y análisis. En la Figura 9 se muestra un ejemplo de la forma en la cual se estructura la información descargada de los drones.

Figura 9: Estructura de Información

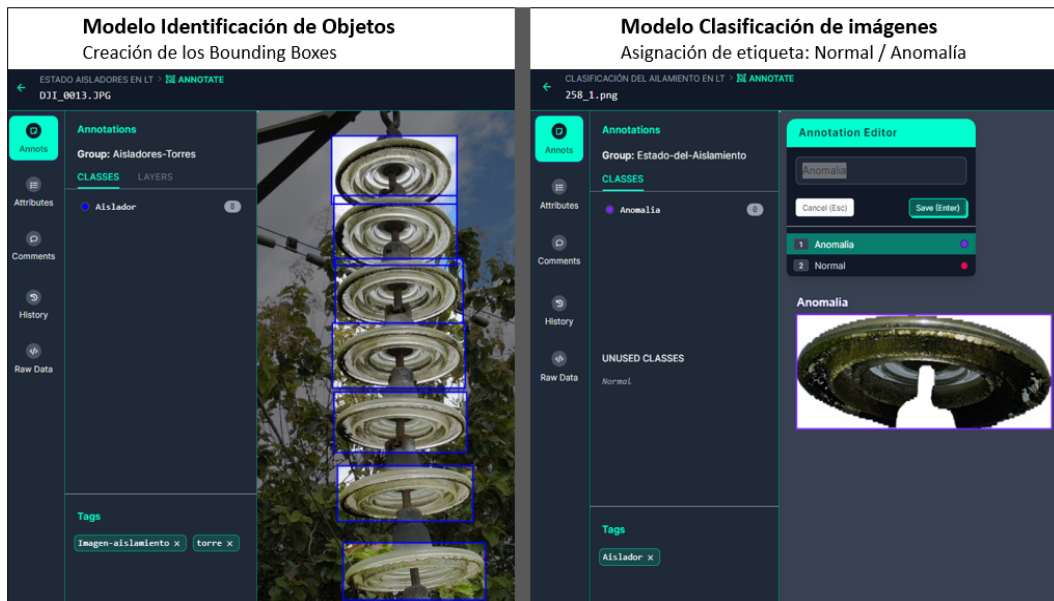


Las imágenes son tomadas por el dron MAVIC2-ENTERPRISE-ADVANCED de la marca DJI, el cual está equipado con una cámara de 48 Megapíxeles y Zoom digital 32x, que permite tomar imágenes con dimensiones de 8000 píxeles de ancho por 6000 píxeles de alto y tienen una representación del color en RGB.

### 4.3. Preparación de los datos

Para el desarrollo de este proyecto, se dispone de un conjunto de datos que consta de un total de 182 imágenes capturadas durante la inspección aérea de una línea de transmisión eléctrica. Como se detallará en la fase de modelado 4.4, se realizó el entrenamiento de dos modelos: uno para la identificación de objetos y otro para la clasificación de imágenes. Para llevar a cabo esta tarea, resulta esencial etiquetar previamente los datos, asignando a cada elemento de las imágenes las categorías correspondientes. En este proceso de etiquetado, se empleó la herramienta RoboFlow [20], que es una plataforma especializada en la construcción y desarrollo de modelos de visión artificial. La Figura 10 muestra la interfaz gráfica y la forma en la cual son etiquetadas las imágenes. Este paso es crítico para garantizar que los modelos de detección de objetos y clasificación de imágenes sean capaces de aprender de manera efectiva a identificar y distinguir los elementos relevantes en las imágenes inspeccionadas.

Figura 10: Interfaz de etiquetado de imágenes en la herramienta RoboFlow



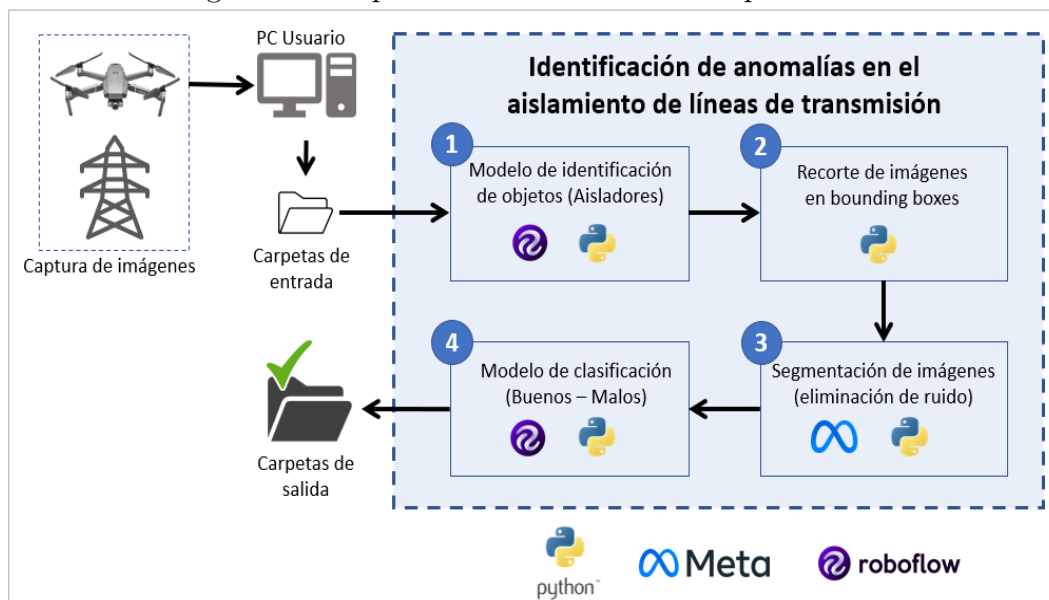
En el proceso de preparación de los datos, se llevó a cabo la división de datos en tres conjuntos distintos: entrenamiento, pruebas y validación, con una proporción de 70 %, 20 % y 10 %, respectivamente. Esta estratificación garantiza que se tenga un conjunto de datos sólido y diverso para el desarrollo y evaluación de los modelos. Para asegurar que todas las imágenes estuvieran correctamente orientadas y tuvieran un tamaño uniforme, se utilizó la funcionalidad “Auto Orient” de Roboflow, lo que simplifica significativamente el procesamiento posterior. Además, se aplicó una operación de “Resize” a las imágenes para normalizar su tamaño, reducir la complejidad, ahorrar espacio de almacenamiento y mejorar la eficiencia durante el entrenamiento de los modelos. Este proceso es crucial para garantizar que el conjunto de datos sea coherente y manejable.

Como paso adicional, se implementaron técnicas de “Data Augmentation” para aumentar la variabilidad en el conjunto de datos. Se aplicaron rotaciones a las imágenes, lo que enseñó a los modelos a reconocer objetos desde múltiples perspectivas. También se utilizó una escala de grises para mitigar los efectos de la iluminación variable debido a la hora del día en que se capturaron las fotografías. Además, se añadió ruido a las imágenes dejando totalmente negro el 5 % de sus píxeles de manera aleatoria, lo que ayuda a que los modelos sean más resistentes a las condiciones de captura de imágenes. Este proceso de aumento de datos contribuye significativamente a la diversidad del conjunto de datos, mejora la capacidad de generalización de los modelos y mitiga el riesgo de sobreajuste.

## 4.4. Modelado

Para abordar el objetivo establecido en el proyecto, en la fase de modelado se diseñó una arquitectura de solución, que como información de entrada recibe las imágenes de las inspecciones de las líneas de transmisión y como salida retorna los hallazgos de las detecciones de anomalía en dichas imágenes. Este proceso involucró la implementación de modelos de identificación de objetos, seguido por un procesamiento de las imágenes identificadas, para finalmente pasar a la etapa de clasificación de las imágenes en dos categorías: “normales” y “con anomalías”. La Figura 11 presenta de manera esquemática la solución implementada, la cual consta de 4 etapas, que serán descritas a continuación:

Figura 11: Arquitectura de la solución implementada



### ▪ Etapa 1. Modelo de identificación de objetos

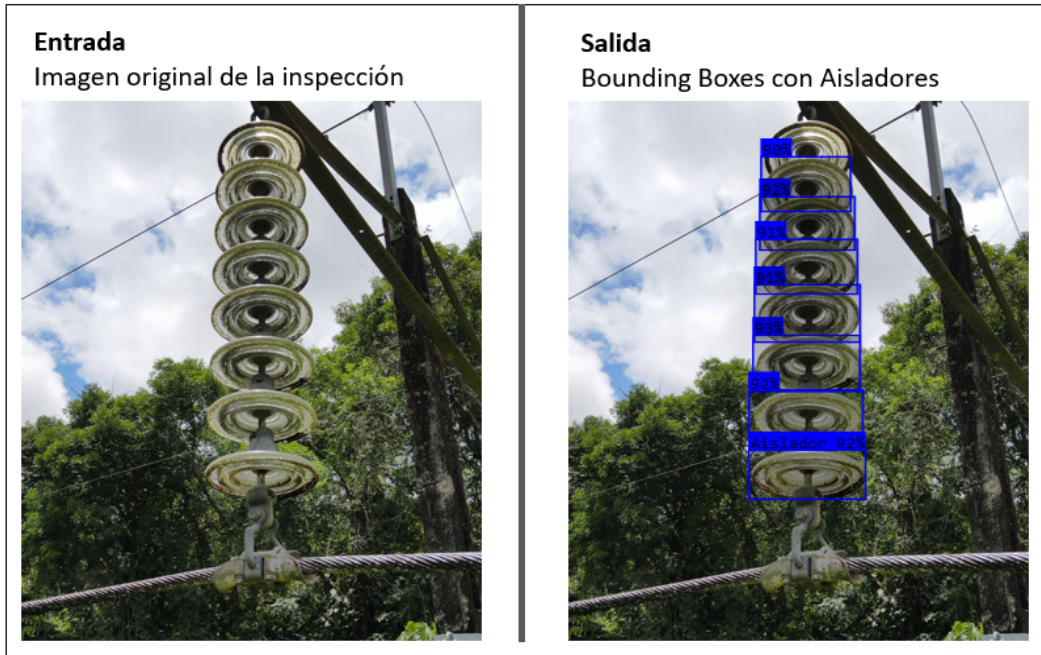
Esta fase tiene como objetivo obtener un modelo de detección de objetos especializado en encontrar los aisladores eléctricos, sin importar en que condición se encuentren estos, y de esta manera facilitar el entrenamiento y el ajuste del modelo, que solo debe estar enfocado en un elemento.

El entrenamiento y ajuste del modelo se llevaron a cabo a través de la plataforma RoboFlow, que brinda la flexibilidad para implementar el modelo utilizando Python junto con la biblioteca RoboFlow, configurando las respectivas “API KEY”. En este proceso, se empleó el algoritmo YOLO v5 para el

entrenamiento del modelo, uno de los más recientes y avanzados en términos de precisión y rendimiento para la identificación de objetos.

Cómo resultado de la predicción se obtienen los “Bounding Boxes” que contienen cada uno de los aisladores eléctricos. (Figura 12).

Figura 12: Entrada y salida del modelo de identificación de objetos

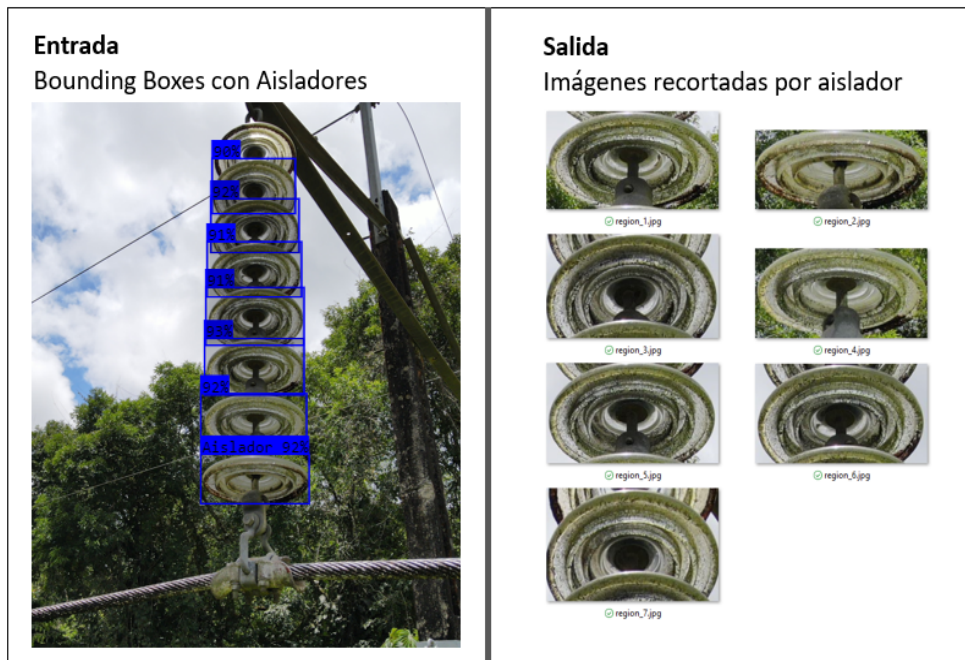


## ▪ Etapa 2. Recorte de imágenes en los “Bounding Boxes”

Como se muestra en la Figura 11 (Arquitectura de la solución implementada), la etapa 2 consiste en recortar las imágenes contenidas en los “Bounding Boxes”. Esto se realiza con el fin de individualizar cada uno de los aisladores, logrando de esta manera segmentar y clasificar la imagen en las etapas posteriores. Este procesamiento se realizó en Python, utilizando como datos de entrada la imagen original y los “Bounding Boxes” obtenidos en la etapa 1, los cuales se encuentran en un formato JSON. Para este procesamiento se requiere realizar una iteración sobre cada “Bounding Box” para recortar el área e ir guardando el resultado en una imagen independiente.

Cómo se observa en la Figura 13, en la etapa de recorte de imágenes se obtiene una imagen independiente por cada elemento aislador identificado en cada uno de los “Bounding Boxes” de la etapa 1.

Figura 13: Entrada y salida de la etapa 2: Recorte de imágenes



### ■ Etapa 3. Segmentación de las imágenes

Con el objetivo de eliminar los factores externos presentes en las imágenes, se empleó el algoritmo de META conocido como “Segment Anything”. Este algoritmo, a partir de uno o varios puntos de entrada en una imagen, comúnmente denominados “prompt”, es capaz de generar una máscara para el objeto de interés. Como se ilustra en la Figura 14, al seleccionar un punto en la imagen recortada del aislador, el algoritmo “Segment Anything” crea una máscara específica que, posteriormente, fue procesada en Python de manera que fuera posible la separación y eliminación del ruido ambiental, como árboles, postes, torres y otros elementos no deseados en las imágenes.

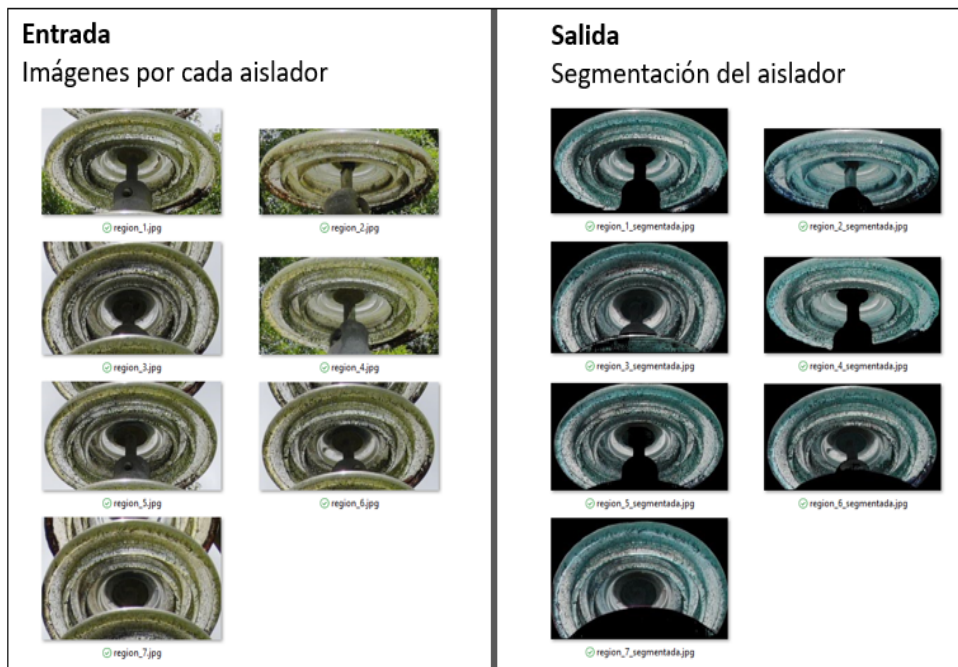
Figura 14: Uso del algoritmo Segment Anything by META



Como se muestra en la Figura 15, durante esta etapa, se toma un conjunto de imágenes, cada una de ellas correspondiente a un plato de aislamiento, y se procesa a través del algoritmo “Segment Anything”. Como resultado de este proceso, se obtiene la misma cantidad de imágenes que al principio, pero con una distinción significativa y es que todas las imágenes generadas contienen exclusivamente el plato de aislamiento en cuestión. En otras palabras, el algoritmo “Segment Anything” se encarga de aislar con precisión el objeto de interés, eliminando cualquier elemento no deseado, como árboles, postes o estructuras circundantes.

Esto se lleva a cabo con la premisa de que, al eliminar los factores externos no deseados, el modelo de clasificación de la etapa 4 podrá obtener resultados más precisos y confiables. Al centrarse exclusivamente en la identificación de anomalías en el plato de aislamiento, se reducen las posibilidades de que elementos externos interfieran con el proceso de clasificación. Esta optimización del conjunto de datos es esencial para garantizar que el modelo se concentre en su tarea principal: identificar y detectar cualquier anomalía en los aisladores con la mayor precisión posible.


Figura 15: Entrada y salida de la etapa 3: Segmentación de imágenes



#### ■ Etapa 4. Modelo de Clasificación de imágenes

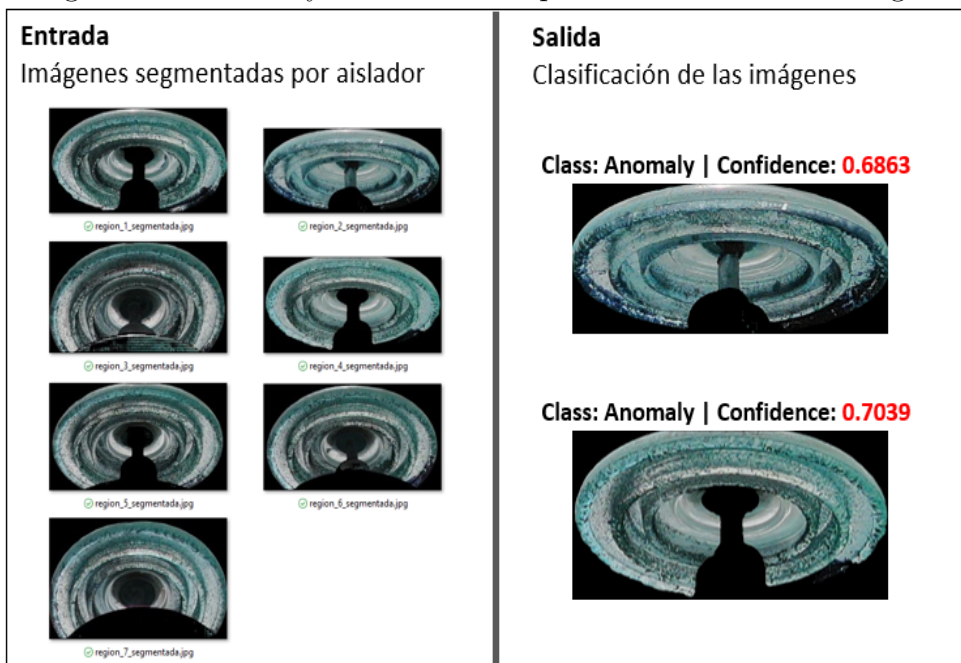
Con el propósito de detectar platos de aislamiento que presenten anomalías, se procedió a entrenar un modelo de clasificación de imágenes ResNet utilizando la plataforma “RoboFlow”. Antes de este proceso, se etiquetaron previamente las imágenes en dos categorías distintas: “Normal” y “Con Anomalía”. En la Figura 16, se presentan algunas imágenes que ilustran el foco principal de esta etapa, que radica en la identificación de la suciedad acumulada en el aislador debido a la proximidad con la vegetación circundante. Esta acumulación de suciedad puede comprometer la capacidad aislante del elemento, aumentando así el riesgo de posibles fallas en el sistema.

Figura 16: Suciedad acumulada en platos de aislamiento



En la etapa de clasificación, se reciben las imágenes resultantes del proceso de segmentación y se procede a su clasificación individual. Cada imagen se somete a una evaluación que arroja como resultado una etiqueta que indica si es “Normal” o “Con Anomalía”, acompañada de un valor de confianza que cuantifica la certeza del modelo en su clasificación. Este enfoque nos permite identificar de manera precisa los elementos que requieren una revisión adicional, ya que el algoritmo es capaz de destacar de manera eficiente las anomalías presentes en las imágenes, como se puede observar en la Figura 17.

Figura 17: Entrada y salida de la etapa 4: Clasificación de imágenes



## 4.5. Evaluación


Como parte de la fase 4.4 se llevó a cabo el entrenamiento de los modelos de identificación de objetos y clasificación de imágenes. A continuación, se expondrán los resultados de la evaluación de estos modelos, lo que permitirá apreciar la capacidad de la metodología implementada durante el desarrollo de este proyecto.

### ■ Evaluación modelo identificación de objetos

En el modelo de identificación de objetos, se obtuvieron resultados sobresalientes durante la evaluación. El Mean Average Precision (mAP) alcanzó un **99.3 %**, lo que refleja la capacidad del modelo para identificar con precisión los aisladores en las imágenes de inspección. La precisión se situó en un **98.3 %**, indicando una baja tasa de falsos positivos, mientras que el Recall obtuvo un **99.4 %**, señalando la efectividad del modelo para identificar todos los aisladores presentes. Estos resultados destacan la capacidad del modelo de identificación de objetos en la detección precisa de aisladores en las imágenes, aclarando que se entrenó de manera exclusiva para la detección de aisladores de vidrio.

Además de estas métricas, se generaron gráficas que muestran la evolución de las pérdidas (losses) durante el entrenamiento, incluyendo pérdida en “Bounding Boxes” (box\_loss), pérdida en clasificación (train/cls\_loss) y pérdida en difusión (train/df\_loss). Estas gráficas se muestran en la Figura 18 y proporcionan una representación visual de cómo el modelo se ajustó durante el proceso de entrenamiento en las diferentes épocas y ayudan a comprender su rendimiento en términos de precisión y capacidad de detección.


Figura 18: Evolución de las pérdidas en el proceso de entrenamiento



### ■ Evaluación modelo clasificación de imágenes

Como se observa en la Figura 19, en el proceso de evaluación del modelo de clasificación, se han obtenido resultados sólidos. El modelo demuestra un Recall del **98.14 %**, lo que indica su eficacia en la identificación de la mayoría de las anomalías en el conjunto de datos. Además, logra una Precision del **98.64 %**, lo que refleja su capacidad para minimizar los errores de clasificación. Estos resultados apuntan a una destacada proporción de verdaderos positivos y a una disminución de los falsos positivos. Esto sugiere que el modelo es confiable en la identificación de anomalías en las imágenes del aislamiento de las líneas de transmisión. Estos hallazgos respaldan la utilidad del modelo para abordar el problema de identificación de problemas en el aislamiento de las líneas de transmisión de manera eficaz.

Figura 19: Métricas modelo de clasificación



## 4.6. Despliegue

En la etapa de despliegue es importante destacar que, debido al alcance del proyecto, no se ha considerado la implementación productiva del modelo de detección de anomalías en el aislamiento de líneas de transmisión. En su lugar, el propósito de este proyecto es evaluar la viabilidad y relevancia de una futura integración de dicho modelo en el contexto de la organización objeto de análisis. Para ello, se ha diseñado un flujo de trabajo que comprende cuatro etapas fundamentales previamente detalladas en la fase de modelado 4.4, a saber: identificación de objetos, recorte de imágenes, segmentación de imágenes y clasificación. El enfoque radica en comprender cómo el modelo podría contribuir a la mejora de los procesos de inspección y mantenimiento de las líneas de transmisión eléctrica dentro de la organización.

## 5. Resultados obtenidos

La implementación propuesta, tal como se detalló en el desarrollo de la metodología en el Capítulo 4, se sometió a una validación utilizando un conjunto de imágenes que no habían sido previamente vistas por ninguno de los modelos durante el proceso de entrenamiento. Esta validación permitió evaluar el desempeño del modelo en condiciones del mundo real, donde se encuentran imágenes diversas y variadas. El resultado de este análisis fue positivo, ya que el modelo demostró un buen desempeño en la detección de anomalías en el aislamiento eléctrico de las líneas de transmisión, esto es evidenciado en la Figura 19, donde se puede observar una precisión del 97.64 % y un Recall de 96 %.

Para garantizar la precisión de estas detecciones, se llevó a cabo una comparación entre las clasificaciones del modelo con la evaluación realizada por un experto, este proceso permitió confirmar que las imágenes clasificadas como “Con anomalías” por el modelo, coincidían con los problemas reales detectados en las imágenes mediante la revisión manual. Estos resultados indican la efectividad de la metodología implementada y su potencial utilidad en la mejora de los procesos de inspección y mantenimiento de las líneas de transmisión eléctrica.

En las Figuras 20 y 21 se presentan los resultados de la implementación al ingresar dos imágenes al modelo. En cada una de las figuras, en el lado izquierdo se muestra la imagen validada por el experto y en la parte derecha el resultado de la aplicación del modelo. Una de estas imágenes representa una cadena de aisladores en mala condición, mientras que la otra muestra una cadena de aisladores en buen estado; en ambos casos es consistente el resultado del modelo con lo indicado por el experto en cuanto a la condición del aislamiento eléctrico.

Figura 20: Resultados predicción en cadena de aislamiento en mal estado





Figura 21: Resultados predicción en cadena de aislamiento en buen estado



Como parte de los resultados del proyecto de Identificación de Anomalías en el Aislamiento de Líneas de Transmisión a partir de Imágenes, se ha creado un repositorio en GitHub. Este repositorio alberga los notebooks en Python que detallan el desarrollo de los modelos y contiene imágenes utilizadas para la validación de la implementación junto con sus etiquetas correspondientes.

Este repositorio se presenta con el propósito de ofrecer un registro detallado del proyecto y servir de base para futuras investigaciones o implementaciones. Además, esta información se entrega como respaldo al desarrollo del proyecto de maestría, proporcionando una visión completa de la metodología aplicada.

<https://github.com/dsance/ProyectoFinalMaestriaDS.git>

## 6. Conclusiones

Los objetivos establecidos para la realización de este proyecto han sido cumplidos de manera satisfactoria. Durante el desarrollo del proyecto, se ha implementado un proceso que comprende tres etapas esenciales en el procesamiento de imágenes: identificación, segmentación y clasificación. La interconexión de estas tres etapas en un mismo flujo, ha demostrado tener un buen rendimiento en la detección de problemas en el aislamiento de las líneas de transmisión de energía eléctrica.

El empleo de herramientas como Roboflow y algoritmos como Segment Anything ha simplificado considerablemente el desarrollo y la implementación de casos de uso basados en el procesamiento de imágenes. Estas herramientas ofrecen interfaces intuitivas y librerías compatibles con Python, permitiendo una implementación eficiente. Esto, a su vez, ha posibilitado asignar un mayor enfoque del proyecto al diseño de la arquitectura de la solución y al análisis de los resultados.

A partir de los resultados observados en este proyecto, se evidencia que la implementación de técnicas de visión artificial para el procesamiento de imágenes en inspecciones de líneas de transmisión eléctrica representa una valiosa oportunidad. Estas técnicas ofrecen una alternativa para optimizar los recursos, permitiendo la identificación temprana de problemas en la infraestructura eléctrica. Este enfoque reduce la carga de trabajo manual, lo que a su vez libera el tiempo de las personas encargadas de esta actividad, que puede ser dedicado a otras tareas del proceso. El proyecto demuestra que la adopción de la visión artificial en esta área puede tener un impacto positivo en la operatividad y el mantenimiento de la infraestructura eléctrica.

Finalmente, se abre la posibilidad de llevar a cabo la implementación del modelo propuesto en un entorno productivo de la empresa. Además, se plantea la opción de explorar otros modelos orientados a la identificación de diversos tipos de problemas en la infraestructura eléctrica. Estos futuros desarrollos representarían una continuación de esta iniciativa, contribuyendo a la mejora de la eficiencia y la seguridad en la gestión de la infraestructura eléctrica.

## Referencias

- [1] Alzate Acevedo, Camilo: *Diseño Conceptual de torres de transmisión de energía utilizando el método de optimización topológica considerando análisis tridimensional y cargas producidas por cables y viento*. Trabajo de grado - Maestría, Universidad Nacional de Colombia, 2016. <https://repositorio.unal.edu.co/handle/unal/58246>.
- [2] Meier, Alexandra von: *Electric Power Systems: A Conceptual Introduction*. 2006.
- [3] *IEEE Guide for Cleaning Insulators*. IEEE Std 957-1995, páginas 1–64, 1995.
- [4] Beleño Díaz, S. L., C. V. Martínez Luna, I. F. Mondragón Bernal y C. A. Parra Rodríguez: *Inspección de aisladores en líneas de transmisión eléctrica usando inteligencia artificial*. 2(36):12, 2020.
- [5] *IEEE Guide for Unmanned Aerial Vehicle-Based Patrol Inspection System for Transmission Lines*. IEEE Std 2821-2020, páginas 1–49, 2020.
- [6] Zheng, Xiangyu, Rong Jia, Aisikaer, Linling Gong, Guangru Zhang y Jian Dang: *Component identification and defect detection in transmission lines based on deep learning*. Journal of Intelligent and Fuzzy Systems, 40, 2021, ISSN 18758967.
- [7] Gönen, Turan: *Electrical Power Transmission System Engineering: Analysis and Design*. Third edition edición, 2014.
- [8] El-Shahat, Mohammed y Hussein Anis: *Assessing Partial Discharge on Composite Insulators Under Desert Pollution Conditions*. International Journal of Emerging Technology and Advanced Engineering, 3, 2013. [https://www.academia.edu/67253369/Assessing\\_Partial\\_Discharge\\_on\\_Composite\\_Insulators\\_Under\\_Desert\\_Pollution\\_Conditions](https://www.academia.edu/67253369/Assessing_Partial_Discharge_on_Composite_Insulators_Under_Desert_Pollution_Conditions).
- [9] *Smart Cities-Automatic Power Lines Inspection*. Volumen 2022-March, 2022.
- [10] Gonzalez, Rafael C. y Richard E. Woods: *Digital Image Processing*. Pearson, Upper Saddle River, NJ, 3rd edición, 2008, ISBN 978-0131687288.
- [11] Szeliski, Richard: *Computer Vision : Algorithms and Applications 2nd Edition*. Springer, 2021.

- [12] ProjectPro: *Computer Vision Tutorial for Beginners — Learn Computer Vision*. <https://www.projectpro.io/data-science-in-python-tutorial/computer-vision-tutorial-for-beginners>.
- [13] Szeliski, Richard: *Computer Vision: Algorithms and Applications*. Springer, 2010.
- [14] Martínez, Andrea y Cano Baños, María: *Estudio práctico de técnicas AI para reconocimiento de objetos*. <https://repositorio.upct.es/bitstream/handle/10317/8864/tfg-mar-est.pdf?sequence=1>.
- [15] Redmon, Joseph, Santosh Divvala, Ross Girshick y Ali Farhadi: *You only look once: Unified, real-time object detection*. Volumen 2016-December, 2016.
- [16] Kirillov, Alexander, Eric Mintun, Nikhila Ravi, Hanzi Mao, Chloe Rolland, Laura Gustafson, Tete Xiao, Spencer Whitehead, Alexander C. Berg, Wan Yen Lo, Piotr Dollár y Ross Girshick: *Segment Anything*, 2023.
- [17] He, Kaiming, Xiangyu Zhang, Shaoqing Ren y Jian Sun: *Deep residual learning for image recognition*. Volumen 2016-December, 2016.
- [18] He, Kaiming, Xiangyu Zhang, Shaoqing Ren y Jian Sun: *Deep Residual Learning for Image Recognition*. arXiv preprint arXiv:1512.03385, 2015.
- [19] IBM, International Business Machines.: *Manual CRISP-DM de IBM SPSS Modeler*. IBM Corporation, 2012.
- [20] Roboflow, Inc. All rights reserved.: *Roboflow*, 2022. <https://roboflow.com/>.
- [21] Chen, Haipeng, Zhentao He, Bowen Shi y Tie Zhong: *Research on Recognition Method of Electrical Components Based on YOLO V3*. IEEE Access, 7, 2019, ISSN 21693536.
- [22] Girshick, R: *Fast R-CNN*, 2015. <https://arxiv.org/abs/1504.08083>.
- [23] Ren, Shaoqing, Kaiming He, Ross Girshick y Jian Sun: *Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 39, 2017, ISSN 01628828.
- [24] He, Kaiming, Georgia Gkioxari, Piotr Dollár y Ross Girshick: *Mask R-CNN*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 42, 2020, ISSN 19393539.