

**UNIVERSIDAD NACIONAL DE JAÉN**  
**FACULTAD DE INGENIERÍA**



**UNIVERSIDAD NACIONAL  
DE JAÉN**

**CARRERA PROFESIONAL DE INGENIERÍA MÉCANICA Y  
ELÉCTRICA**

**APLICACIÓN DE DEEP LEARNING Y DRON EN UNA  
LÍNEA DE TRANSMISIÓN PARA AUMENTAR LA  
PRODUCTIVIDAD EN DETECCIÓN DE FALLAS EN  
AISLADORES, JAÉN-CAJAMARCA**

**TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE  
INGENIERO MECÁNICO ELECTRICISTA**

**Autor(es): Bach. Juan Eduardo Laban Chuquipoma**

**Bach. Salomón Cubas Quevedo**

**Asesor(es): M.Sc. Ing. Luis Miguel Llanos Sánchez**

**Dr. Ing. Ricardo Ángel Shimabuku Ysa**




**Línea de investigación: automatización y control industrial**

**JAÉN – PERÚ**

**2026**

# Juan Eduardo Laban Chuquipoma y Salomón Cubas ...

## APLICACIÓN DE DEEP LEARNING Y DRON EN UNA LÍNEA DE TRANSMISIÓN PARA AUMENTAR LA PRODUCTIVIDAD EN DE...

-  Prueba 1
-  Proyectos
-  Universidad Nacional de Jaen

### Detalles del documento

Identificador de la entrega  
trnoid:::1:3519164255

111 páginas

Fecha de entrega  
27 mar 2026, 9:40 a.m. GMT-5

15.128 palabras

Fecha de descarga  
27 mar 2026, 9:46 a.m. GMT-5

90.342 caracteres

Nombre del archivo  
APLICACIÓN\_DE\_DEEP\_LEARNING\_Y\_DRON\_EN\_UNA\_LÍNEA\_DE\_TRANSMISIÓN\_PARA\_AUMENTAR\_....pdf

Tamaño del archivo  
10.7 MB

 UNIVERSIDAD NACIONAL DE JAEN  
  
Dr. Christian Aquilino Panca  
RESPONSABLE DEL CENTRO DE INVESTIGACIÓN  
DE LA FACULTAD DE INGENIERÍA

## 13% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

### Filtrado desde el informe

- Bibliografía
- Coincidencias menores (menos de 15 palabras)

### Fuentes principales

- 5% Fuentes de Internet
- 1% Publicaciones
- 11% Trabajos entregados (trabajos del estudiante)

### Marcas de integridad

N.º de alertas de integridad para revisión

- Caracteres reemplazados**  
104 caracteres sospechosos en N.º de páginas  
Las letras son intercambiadas por caracteres similares de otro alfabeto.
- Texto oculto**  
395 caracteres sospechosos en N.º de página  
El texto es alterado para mezclarse con el fondo blanco del documento.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

UNIVERSIDAD NACIONAL DE JAÉN  
  
**Dr. Christiaan Zayed Apaza Panca**  
RESPONSABLE DE LA UNIDAD DE INVESTIGACIÓN  
DE LA FACULTAD DE INGENIERÍA



### FORMATO 03: ACTA DE SUSTENTACIÓN

En la ciudad de Jaén, el día lunes 07 de abril del 2026, siendo las 17:00 horas, se reunieron los integrantes del Jurado:

Presidente : Mg. José Andrés Fernández Mera  
Secretario : Mg. Mario Félix Olivera Aldana  
Vocal : Mg. Jaime Odar Honorio Acosta

Para evaluar la Sustentación del Informe Final:

- ( ) Trabajo de Investigación  
( X ) Tesis  
( ) Trabajo de Suficiencia Profesional

Titulado: "APLICACIÓN DE DEEP LEARNING Y DRON EN UNA LÍNEA DE TRANSMISIÓN PARA AUMENTAR LA PRODUCTIVIDAD EN DETECCIÓN DE FALLAS EN AISLADORES, JAÉN-CAJAMARCA".

Presentado por los bachilleres: **Juan Eduardo Laban Chuquipoma y Salomón Cubas Quevedo** de la Escuela Profesional de INGENIERÍA MECÁNICA Y ELÉCTRICA.

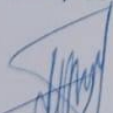
Después de la sustentación y defensa, el Jurado acuerda:

- ( X ) Aprobar ( ) Desaprobar ( X ) Unanimidad ( ) Mayoría

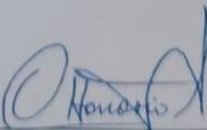
Con la siguiente mención:

a) Excelente	18, 19 20	( )
b) Muy bueno	16, 17	( 16 )
c) Bueno	14, 15	( )
d) Regular	13	( )
e) Desaprobado	12 ó menos	( )

Siendo las 18:00 horas del mismo día, el Jurado concluye el acto de sustentación confirmando con la suscripción de la presente.

  
Mg. José Andrés Fernández Mera  
Presidente Jurado Evaluador

  
Mg. Mario Félix Olivera Aldana  
Secretario Jurado Evaluador

  
Mg. Jaime Odar Honorio Acosta  
Vocal Jurado Evaluador

**“Año de la Esperanza y el Fortalecimiento de la Democracia”**

**ANEXO N°06:**

**DECLARACIÓN JURADA DE AUTENTICIDAD Y DE NO PLAGIO  
DE LA TESIS O TRABAJO DE INVESTIGACIÓN (PREGRADO)**

Nosotros, **Juan Eduardo Laban Chuquipoma**, y **Salomón Cubas Quevedo** egresados de la carrera Profesional de Ingeniería Mecánica y Eléctrica de la Facultad de Ingeniería de la Universidad Nacional de Jaén, identificados con **DNI: 75628153** y **DNI: 47968487**.

Declaramos bajo juramento que:

1. Somos autores del trabajo titulado:

**“APLICACIÓN DE DEEP LEARNING Y DRON EN UNA LÍNEA DE TRANSMISIÓN PARA AUMENTAR LA PRODUCTIVIDAD EN DETECCIÓN DE FALLAS EN AISLADORES, JAÉN-CAJAMARCA”.**

Asesorado por M.Sc. Ing. Luis Miguel Llanos Sánchez, y Dr. Ing. Ricardo Ángel Shimabuku Ysa.

El mismo que presentamos bajo la modalidad de tesis para optar; el Título Profesional/Grado Académico de Ingeniero Mecánico Electricista

2. El texto de nuestro trabajo final respeta y no vulnera los derechos de terceros, incluidos los derechos de propiedad intelectual. En el sentido, el texto de mi trabajo final no ha sido plagiado total ni parcialmente, para la cual he respetado las normas internacionales de citas y referencias de las fuentes consultadas.
3. El texto del trabajo final que presento no ha sido publicado ni presentado antes en cualquier medio electrónico o físico.
4. La investigación, los resultados, datos, conclusiones y demás información presentada que atribuyo a mi autoría son veraces.
5. Declaro que mi trabajo final cumple con todas las normas de la Universidad Nacional de Jaén.
6. Somos conscientes de que el hecho de no respetar los derechos de autor y hacer plagio, es objeto de sanciones universitarias y/o legales.

El incumplimiento de lo declarado da lugar a responsabilidad del declarante, en consecuencia; a través del presente documento asumo frente a terceros, la Universidad Nacional de Jaén y/o la Administración Pública toda responsabilidad que pueda derivarse por el trabajo final presentado. Lo señalado incluye responsabilidad pecuniaria incluido el pago de multas u otros por los daños y perjuicios que se ocasionen.

Jaén 16 de abril del 2026



Juan Eduardo Laban Chuquipoma



Salomón Cubas Quevedo

## ÍNDICE

<b>RESUMEN</b> .....	<b>xi</b>
<b>ABSTRACT</b> .....	<b>xii</b>
<b>I INTRODUCCIÓN</b> .....	<b>13</b>
<b>II MATERIALES Y MÉTODOS</b> .....	<b>17</b>
2.1. OBJETO DE ESTUDIO .....	17
2.2. UBICACIÓN DEL AREA DE ESTUDIO .....	17
2.3. POBLACIÓN Y MUESTRA .....	19
2.4. VARIABLES DE ESTUDIO .....	19
2.4.1. Operacionalización de variables .....	20
2.5. MÉTODOS .....	21
2.5.1. Método de investigación .....	21
2.5.2. Tipo de investigación .....	21
2.5.3. Enfoque o nivel de investigación .....	21
2.5.4. Diseño de investigación .....	21
2.6. TÉCNICAS E INSTRUMENTOS .....	22
2.6.1. Entrevista .....	22
2.6.2. Guía de entrevista estructurada .....	22
2.6.3. Validez y confiabilidad .....	22
2.7. PROCEDIMIENTO .....	23
2.7.1. Equipos y Materiales .....	23
2.7.2. Recolección de datos del procedimiento actual de inspección y detección de fallas de aisladores en líneas de transmisión .....	23
2.7.3. Desarrollo del modelo Deep Learning para detección automática de fallas en aisladores .....	26
<b>III RESULTADOS</b> .....	<b>49</b>
3.1. Recolección de datos del procedimiento tradicional de inspección de aisladores en líneas de transmisión .....	49
3.2. Desarrollo del modelo Deep Learning para detección automática de fallas en aisladores .....	51
3.3. Comparación de la productividad en detección de fallas de aisladores con el modelo Deep Learning y el método tradicional .....	65
<b>IV DISCUSIÓN</b> .....	<b>69</b>
<b>V CONCLUSIONES Y RECOMENDACIONES</b> .....	<b>71</b>
5.1. Conclusiones .....	71
5.2. Recomendaciones .....	72
<b>VI REFERENCIAS BIBLIOGRÁFICAS</b> .....	<b>73</b>
<b>AGRADECIMIENTO</b> .....	<b>78</b>
<b>DEDICATORIA</b> .....	<b>78</b>
<b>ANEXOS</b> .....	<b>79</b>

## ÍNDICE DE TABLAS

<b>Tabla 1</b> <i>Operacionalización de Variables</i> .....	20
<b>Tabla 2</b> <i>Equipos y Materiales</i> .....	23
<b>Tabla 3</b> <i>Información obtenida en la entrevista</i> .....	26
<b>Tabla 4</b> <i>Características del dron Phantom 4RTK</i> .....	27
<b>Tabla 5</b> <i>Tiempos operativos por estructura en la inspección</i> .....	30
<b>Tabla 6</b> <i>Costos por la inspección diaria con dron Phantom 4RTK</i> .....	31
<b>Tabla 7</b> <i>Modelos de Yolov11</i> .....	42
<b>Tabla 8</b> <i>Estructura de Yolo v11</i> .....	43
<b>Tabla 9</b> <i>Parámetros del modelo</i> .....	46
<b>Tabla 10</b> <i>Matriz de confusión</i> .....	47
<b>Tabla 11</b> <i>Costos Operativos del Método Tradicional de Inspección</i> .....	49
<b>Tabla 12</b> <i>Rendimiento por inspección de estructuras</i> .....	50
<b>Tabla 13</b> <i>Registro de tiempo de evaluación de imágenes de aisladores en gabinete técnico</i> .....	51
<b>Tabla 14</b> <i>Estados propuestos para la clasificación de aisladores</i> .....	52
<b>Tabla 15</b> <i>Métricas de evaluación del modelo YOLOv11 para el conjunto de validación</i> .....	59
<b>Tabla 16</b> <i>Resultado matriz de confusión</i> .....	62
<b>Tabla 17</b> <i>Registro de tiempos de evaluación de imágenes en gabinete con Deep Learning</i> .....	64
<b>Tabla 18</b> <i>Productividad entre el método tradicional y el método Deep Learning y dron</i> .....	68

## ÍNDICE DE FIGURAS

<b>Figura 1</b> <i>Ubicación del área de estudio</i> .....	18
<b>Figura 2</b> <i>Diagrama del procedimiento de la investigación</i> .....	22
<b>Figura 3</b> <i>Diagrama del proceso de inspección con el método tradicional</i> .....	24
<b>Figura 4</b> <i>Inspección tradicional de las líneas de transmisión</i> .....	25
<b>Figura 5</b> <i>Fijación de hélices y batería</i> .....	28
<b>Figura 6</b> <i>Realización de la inspección con dron</i> .....	28
<b>Figura 7</b> <i>Toma de fotografías con el Dron Phantom 4 RTK</i> .....	29
<b>Figura 8</b> <i>Diagrama del modelo Deep Learning</i> .....	32
<b>Figura 9</b> <i>Base de datos de aisladores buenos</i> .....	34
<b>Figura 10</b> <i>Base de datos de aisladores sucios</i> .....	35
<b>Figura 11</b> <i>Base de datos de aisladores rotos/flameados</i> .....	36
<b>Figura 12</b> <i>Creación del proyecto en Label-Studio</i> .....	38
<b>Figura 13</b> <i>Etiquetado de las imágenes mediante cajas delimitadoras</i> .....	38
<b>Figura 14</b> <i>Exportación de la base de datos para YOLO v11</i> .....	39
<b>Figura 15</b> <i>Estructura de Yolo v11</i> .....	40
<b>Figura 16</b> <i>Segmentación de la imagen en cuadrículas de tamaño SxS</i> .....	41
<b>Figura 17</b> <i>Definición del modelo en Python</i> .....	43
<b>Figura 18</b> <i>Creación del archivo YAML con las clases</i> .....	45
<b>Figura 19</b> <i>Entrenamiento del modelo Yolo v11</i> .....	46
<b>Figura 20</b> <i>Base de datos de las diferentes fallas en aisladores</i> .....	53
<b>Figura 21</b> <i>Instancias de la base de datos</i> .....	54
<b>Figura 22</b> <i>Análisis correlacional de las variables</i> .....	55
<b>Figura 23</b> <i>Mosaico de predicciones del modelo YOLOv11</i> .....	57
<b>Figura 24</b> <i>Gráficas del entrenamiento y validación</i> .....	58
<b>Figura 25</b> <i>Resultados del entrenamiento y validación del modelo Yolo v11(Yolon.pt)</i> . 60	

<b>Figura 26</b> <i>Resultados de detección de los aisladores roto/flameado</i> .....	61
<b>Figura 27</b> <i>Matriz de confusión</i> .....	63
<b>Figura 28</b> <i>Evaluación en gabinete con modelo Deep Learning</i> .....	64
<b>Figura 29</b> <i>Productividad de inspecciones diarias con ambos métodos</i> .....	66
<b>Figura 30</b> <i>Costo de inspección diaria con ambos métodos</i> .....	66
<b>Figura 31</b> <i>Personal requerido para la inspección de aisladores</i> .....	67
<b>Figura 32</b> <i>Tiempo de procesamiento de imágenes en gabinete</i> .....	68

## ÍNDICE DE ANEXOS

<b>Anexo 1</b> <i>Objeto de Estudio</i> .....	79
<b>Anexo 2</b> <i>Población y muestra</i> .....	80
<b>Anexo 3</b> <i>Instrumento de recolección de datos</i> .....	81
<b>Anexo 4</b> <i>Validación del instrumento de recolección de datos</i> .....	82
<b>Anexo 5</b> <i>Desarrollo de entrevista estructurada</i> .....	85
<b>Anexo 6</b> <i>Autorización de Electro Oriente para el vuelo del dron</i> .....	89
<b>Anexo 7</b> <i>Autorización de salida de dron – UNJ</i> .....	90
<b>Anexo 8</b> <i>Especificaciones técnicas del dron</i> .....	91
<b>Anexo 9</b> <i>Inspección de aisladores con dron</i> .....	92
<b>Anexo 10</b> <i>Preprocesamiento de imágenes</i> .....	93
<b>Anexo 11</b> <i>Aisladores buenos</i> .....	93
<b>Anexo 12</b> <i>Aisladores sucios</i> .....	95
<b>Anexo 13</b> <i>Aisladores Dañados</i> .....	98
<b>Anexo 14</b> <i>Preparación de Dataset</i> .....	100
<b>Anexo 15</b> <i>Etiquetado de aisladores en Label Studio</i> .....	101
<b>Anexo 16</b> <i>Estructura del Dataset</i> .....	102
<b>Anexo 17</b> <i>Creación de la lista de clases data.yaml</i> .....	103
<b>Anexo 18</b> <i>División del conjunto de datos, entrenamiento y validación</i> .....	104
<b>Anexo 19</b> <i>Entrenamiento del YOLOv11 con el Dataset</i> .....	105
<b>Anexo 20</b> <i>Generación de predicciones con el modelo</i> .....	110

## RESUMEN

La investigación aborda el problema de la baja productividad, el elevado tiempo de procesamiento y los riesgos operativos asociados al método tradicional de inspección visual de aisladores en líneas de transmisión, el cual depende de la experiencia del personal y presenta limitaciones para la detección oportuna de fallas. El objetivo general fue aplicar Deep Learning y dron en una línea de transmisión para aumentar la productividad en detección de fallas en aisladores, Jaén – Cajamarca. Se desarrolló una investigación aplicada, con enfoque cuantitativo y diseño no experimental, recopilándose información del procedimiento tradicional mediante entrevista y observación; posteriormente se implementó un modelo de detección automática basado en YOLOv11, entrenado con una base de datos de 2239 imágenes de aisladores en buen estado, sucios, roto/flameado y validado con 430 imágenes, y se comparó el rendimiento frente al método tradicional. Los resultados evidenciaron que el método tradicional permite inspeccionar entre 8 y 10 estructuras por día, mientras que la integración con dron y Deep Learning incrementó la capacidad a 42 estructuras por jornada; además el modelo alcanzó una precisión del 95.6%, un Recall del 96.3% y una mAP@0.5 de 97.7%, reduciendo el tiempo de análisis en gabinete de 72 a 0.55 segundos por imagen. Se concluye que la propuesta incrementa la productividad en 367%, reduce costos en 19% y minimiza riesgos operativos, constituyéndose una alternativa tecnológica eficiente y viable para modernizar los procesos de inspección de infraestructuras eléctricas.

**Palabras clave:** Deep Learning, dron, YOLOv11, productividad, aisladores.

## ABSTRACT

The research addresses the problem of low productivity, long processing, and operational risks associated with the traditional method of visual inspection of insulators on transmission lines, which depends on the experience of personnel and has limitation for the timely detection of faults. The overall objective was to apply deep learning and drones to a transmission line to increase productivity in detecting insulator faults in Jaén-Cajamarca. Applied research was conducted using a quantitative approach and non-experimental design, gathering information on the traditional procedure through interviews and observation. Subsequently, an automatic detection model based on YOLOv11 was implemented, trained with a database of 2239 images of insulators in good condition, dirty, broken/flamed, and validated with 430 images, and its performance was compared to the traditional method. The results showed that the traditional method allows for the inspection of between of 8 and 10 structures per day, while the integration with drones and deep learning increased the capacity to 42 structures per day. In addition, the model achieved an accuracy of 95.6%, a recall of 96.3%, and a precision of 97.7%, reducing the analysis time in the office from 72 to 0.55 seconds per image. It is concluded that the proposal increases productivity by 367%, reduces costs by 19%, and minimizes operational risks, constituting an efficient and viable technological alternative for modernizing electrical infrastructure inspection processes.

**Keywords:** Deep Learning, drone, YOLOv11, productivity, insulators.

## I INTRODUCCIÓN

La inspección y el mantenimiento de las líneas de transmisión de energía eléctrica son fundamentales para garantizar la confiabilidad, seguridad y continuidad del suministro eléctrico, ya que cualquier falla de sus componentes puede generar interrupciones del servicio, pérdidas económicas y riesgos para la seguridad pública. En particular, los aisladores cumplen una función crítica al soportar mecánicamente los conductores y proporcionar el aislamiento eléctrico entre estos y las estructuras; por ello su deterioro puede provocar descargas superficiales, arcos eléctricos o fallas en la red (GEDISA,2013). Tradicionalmente, la detección de fallas en aisladores se realizan mediante inspecciones visuales, llevadas a cabo por personal especializado desde tierra, no obstante este método presenta limitaciones significativas ya que depende de la experiencia del inspector, es susceptible a errores humanos y resulta poco eficiente debido a limitada observación desde el suelo para identificar defectos visibles en los aisladores como roturas, contaminación superficial o evidencias de descargas eléctricas (Electric Power Research Institute [EPRI], 2016).

En los últimos años, el avance en tecnologías como el Deep Learning y los drones han abierto nuevas posibilidades para la inspección de infraestructura de manera más eficiente y precisa (Faisal et al., 2025). Diversas investigaciones han demostrado la efectividad del Deep Learning para la detección de fallas en aisladores.

En el ámbito internacional, Belaño et al. (2020) propuso un sistema de inspección de aisladores mediante inteligencia artificial, obteniendo una precisión del 95% a través del algoritmo YOLO. La integración de drones con Deep Learning para la inspección de líneas de transmisión ha ganado relevancia debido a su capacidad para acceder áreas de difícil acceso y recopilar datos de manera rápida y segura. Li et al. (2023) desarrolló un sistema automatizado basado en aprendizaje profundo para el análisis y procesamientos de imágenes de inspección de líneas eléctricas, su estudio alcanzó una precisión del 91.36% en la detección de fallas en aisladores. Jicheng (2021). Presentó un método automatizado para la detección de fallas en aisladores a partir de imágenes aéreas, basado en técnicas de aprendizaje profundo (Deep Learning). Combinó la red Single Shot Multibox detector (SSD), utilizada para localizar y extraer características de los aisladores, con la red DenseNet para clasificar de forma precisa los tipos de fallas. Para la escasez de datos, aplicó una estrategia de aumento de datos en dos

fases. La primera basada en la combinación de imágenes y la segunda que incluyó transformación afín aleatorio, desenfoque gaussiano, variación de brillo y contraste, y ruido de tipo sal y pimienta. Sus resultados mostraron una precisión del 95% en la detección de las fallas y del 98% en la clasificación del tipo de falla. De igual manera, Astudillo (2022) desarrolló un sistema autónomo para la identificación de fallas en aisladores utilizando técnicas de visión artificial. Conformó una base de datos compuesta por 3000 imágenes de aisladores, los cuales fueron clasificadas en sucios/flameados, rotos y en buen estado. Con este conjunto de datos entrenó el algoritmo YOLO (You Only Look Once), basado en redes neuronales convolucionales (CNN), para la detección de fallas en aisladores en tiempo real, así como en imágenes capturadas por dron y videos pregrabados. Además, diseño una interfaz gráfica que facilita la operatividad del sistema, permitiendo su uso por usuarios con conocimientos técnicos básicos. Sus resultados alcanzaron una precisión del 87.5% en tiempo real, 94% en imágenes estáticas y 89% en videos pregrabados. Por su parte, Fahim y Hasan (2024) desarrollaron una investigación orientada a la evaluación de fallas en aisladores mediante los algoritmos YOLO v7 y YOLO v8, los cuales fueron entrenados con un conjunto de imágenes etiquetadas de aisladores rotos, flameados y en buen estado. Sus resultados demostraron que YOLO v8 obtuvo un desempeño superior, alcanzando una precisión del 98.99% y una mAP del 99.10%. Astudillo y Catota (2025) propusieron un sistema automatizado para la detección de fallas de aisladores de líneas de distribución eléctrica mediante visión artificial integrada en vehículos aéreos no tripulados. La metodología empleó el modelo YOLOv5 basado en redes neuronales convolucionales para el análisis de aproximadamente 3000 imágenes, permitiendo identificar deterioros como acumulación de materia orgánica, fisuras y roturas. Los resultados evidenciaron una precisión global de 93% y un Recall o sensibilidad de 90% en detección de fallas. Además, obtuvo un tiempo promedio de detección por imagen de 2 segundos en procesamiento a bordo y 1 segundo fuera de línea, demostrando que la solución propuesta optimiza los tiempos de inspección y mejora la precisión de diagnóstico y facilita la planificación del mantenimiento, contribuyendo a la reducción de costos y al incremento de confiabilidad del sistema eléctrico.

En el ámbito nacional, estudios como Opazo (2020), propuso un sistema automatizado para la detección de torres de alta tensión y la clasificación de su nivel de corrosión, utilizando imágenes captadas por drones y modelos de aprendizaje profundo. La metodología se organizó en tres etapas: detección de la torre mediante RCNN y VGG16, clasificación con AlexNet y el optimizador Adam para reducir falsos positivos, y un clasificador de corrosión basado en VGG16. Sus resultados arrojaron una precisión promedio de 60% en detección, 99.5% en clasificación de torres y 89.5% en clasificación del nivel de corrosión, demostrando la eficacia del enfoque para inspecciones automatizadas en infraestructuras eléctricas. Por otro lado, Silva (2023) en la Universidad Cesar Vallejo, implementó drones para el registro de mediciones eléctricas en redes de baja tensión, logrando una reducción del personal técnico de 4 a 2, lo que representó una disminución del 50% del equipo de trabajo habitual, y una mejora del tiempo de 20 – 30 minutos a solo 8 – 10 minutos, lo que equivale una mejora del 69% en la eficiencia del proceso, un aumento del 220% en productividad y una mejora del 100% en seguridad, al eliminar la intervención directa del personal técnico. Huallpa (2020), optimizó la supervisión de líneas de media tensión mediante dron, reduciendo el tiempo de inspección de 111 a 49 días (ahorro de 55.9%) y aumentando la productividad en 54.5%, además de lograr un ahorro económico del 63.99% respecto al método tradicional. Finalmente, Canchaya (2021), demostró la eficacia de los VANT para la supervisión remota de líneas de transmisión, incrementando la cantidad de estructuras inspeccionadas por día de 18 a 49 y reduciendo el tiempo por inspección de 24 a 11 minutos.

En relación con los antecedentes presentados, los cuales evidencian el uso creciente de tecnologías como el Deep Learning y los Drones en la inspección de infraestructuras eléctricas, resulta necesario fundamentar teóricamente las variables que intervienen en la presente investigación, con el fin de comprender su relación y sustentar el planteamiento del problema.

El Deep Learning, es una subárea del aprendizaje automático que emplea redes neuronales profundas para el análisis de grandes volúmenes de datos, especialmente de imágenes. Estas redes permiten la extracción de características relevantes, logrando altos niveles de precisión en tareas de detección y clasificación (LeCun et al., 2015). En el ámbito de visión por computadora, algoritmos como You Only Look

Once (YOLO) han demostrado ser eficientes en la identificación y clasificación de objetos (Redmon et al., 2016). Por su parte los drones o vehículos aéreos no tripulados permiten la captura de imágenes áreas en zonas de difícil acceso controlados de forma remota desde tierra o automáticamente mediante GPS y sensores.

En cuanto a la productividad, esta se define como a la relación entre los resultados obtenidos y los recursos utilizados (Fontalvo et al., 2017). En el contexto de inspección de aisladores de líneas de transmisión, se mide mediante indicadores como el número de estructuras por día, tiempo empleado y costos operativos.

A pesar de los avances tecnológicos descritos en los antecedentes y bases teóricas, en la provincia de Jaén, las empresas responsables de la inspección y el mantenimiento de las líneas de transmisión y redes de distribución continúan utilizando métodos tradicionales donde enfrentan riesgos y desafíos en la detección temprana de fallas en los aisladores; componentes esenciales para garantizar la integridad y estabilidad del suministro eléctrico.

Tradicionalmente las inspecciones de aisladores se realizan mediante métodos visuales desde el suelo con el uso de binoculares y captura de imágenes de los aisladores mediante dispositivos celular para su posterior análisis y clasificación en gabinete. Sin embargo, este procedimiento presenta distintas limitaciones operativas importantes, tales como dificultades para observar adecuadamente los aisladores, dependencia de las condiciones de iluminación, y la posibilidad de pasar por alto fallas menores no visibles desde el suelo. Como resultado, el proceso de inspección se torna laborioso y con menor precisión, lo que reduce la eficiencia y productividad de las labores de mantenimiento preventivo, elevando los costos operativos.

Ante esta problemática mencionada, surge la pregunta ¿En qué medida la aplicación de Deep Learning y dron puede aumentar la productividad en detección de fallas en aisladores en una línea de transmisión, Jaén – Cajamarca?

La importancia de este estudio radica en la necesidad de modernizar los procesos de inspección de las líneas de transmisión mediante el uso de tecnologías emergentes. A nivel tecnológico, propone una solución innovadora para un problema operativo frecuente en el sector eléctrico. A nivel económico, busca reducir los tiempos de inspección y costos asociados a mantenimientos. Y desde una perspectiva social,

mejora la seguridad del personal técnico y contribuye a la estabilidad del suministro eléctrico, lo cual beneficia directamente a la población usuaria. En el ámbito ambiental, el uso de drones y Deep Learning reduce el impacto sobre el entorno al minimizar desplazamientos y emisiones de vehículos durante las labores de inspección.

En ese sentido, la presente tesis tiene como objetivo principal aplicar Deep Learning y dron en una línea de transmisión para aumentar la productividad en detección de fallas en aisladores, Jaén – Cajamarca.

Objetivos específicos:

- Recolección de datos del procedimiento actual de inspección y detección de fallas de aisladores en líneas de transmisión.
- Desarrollar un modelo Deep Learning para detección automática de fallas en aisladores de una línea de transmisión en Jaén-Cajamarca utilizando imágenes recopilados por dron.
- Comparar la productividad en detección de fallas de aisladores con el modelo Deep Learning, contrastándola con el método tradicional.

## **II MATERIALES Y MÉTODOS**

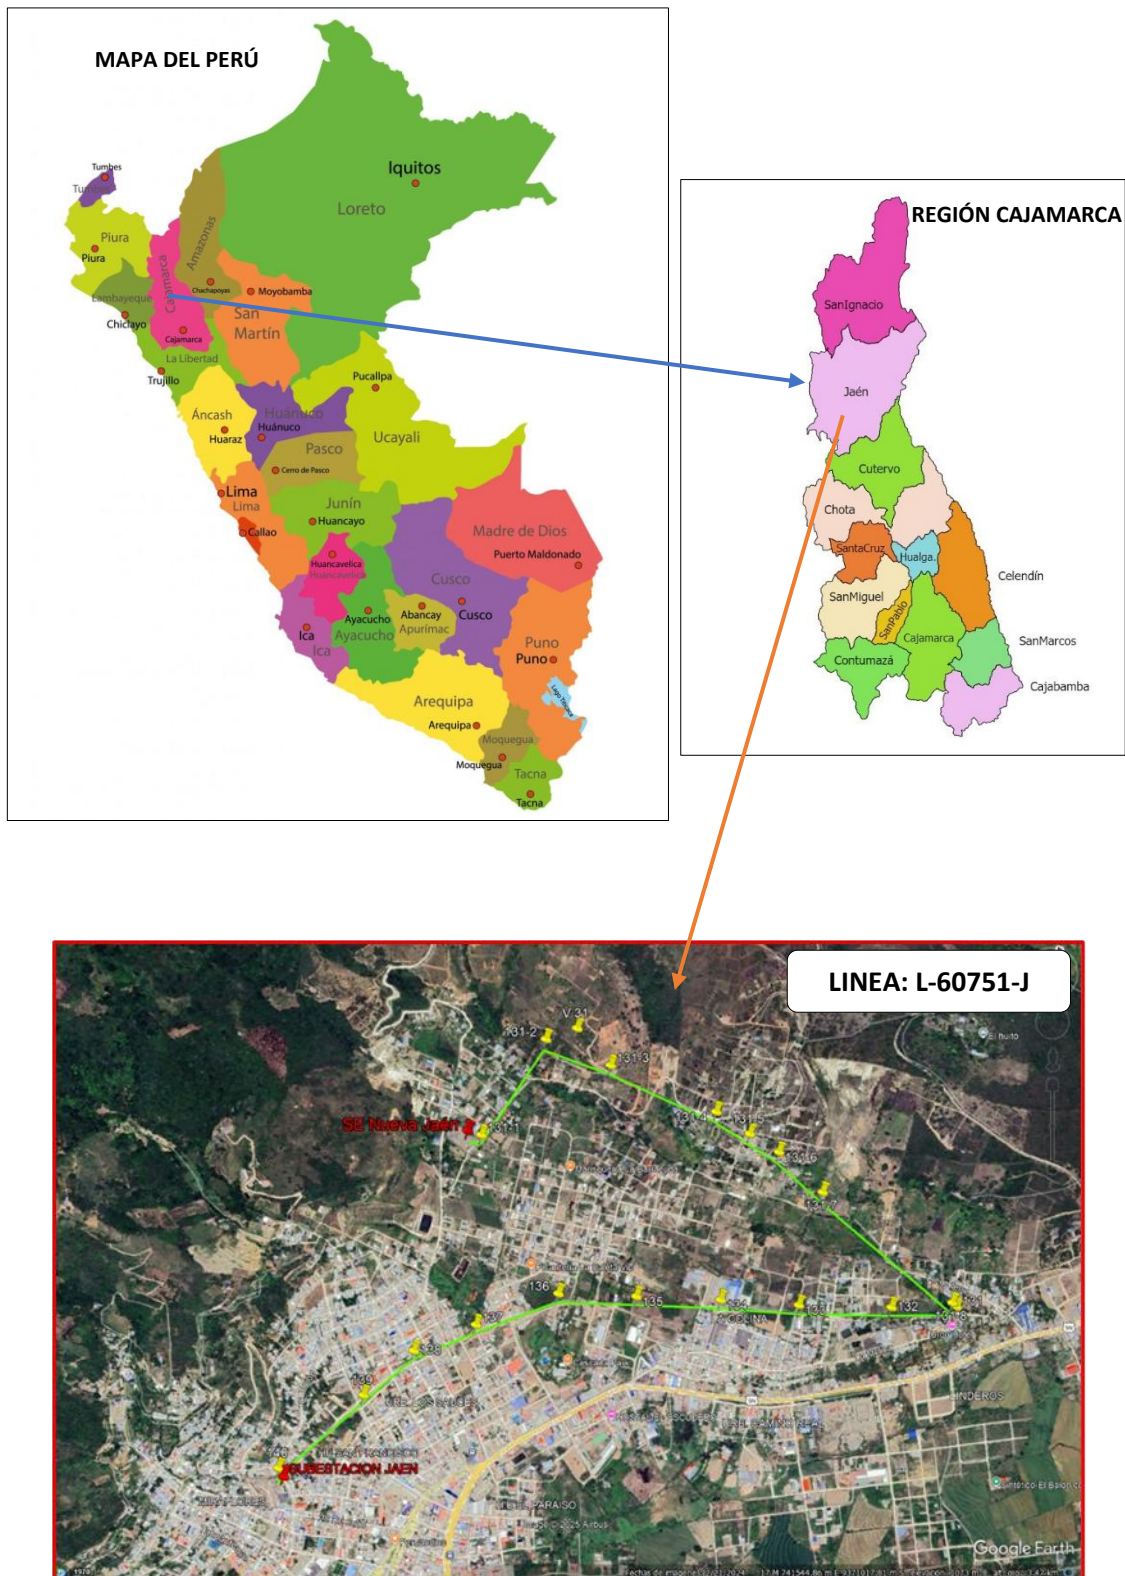
### **2.1. OBJETO DE ESTUDIO**

En la presente investigación, el objeto de estudio estuvo comprendida por los aisladores eléctricos instalados en las 17 estructuras de la línea de transmisión de 60 kV, correspondiente entre la Subestación Nueva Jaén y la Subestación Jaén. Se evaluaron los estados físicos de los aisladores mediante imágenes capturadas por dron, con la finalidad de identificar fallas visibles como suciedad, fisuras, fracturas o flameos (Ver anexo 1).

### **2.2. UBICACIÓN DEL AREA DE ESTUDIO**

El estudio de la presente investigación se desarrolló en la provincia de Jaén, región Cajamarca, específicamente a lo largo de la línea de transmisión de 4.17 km de longitud entre la Subestación Nueva Jaén y la Subestación Jaén.

**Figura 1**  
*Ubicación del área de estudio*



Fuente: Elaboración propia

### **2.3. POBLACIÓN Y MUESTRA**

La población de la presente investigación estuvo conformada por las 17 estructuras de la línea de transmisión SE Nueva Jaén – SE Jaén. Según Arias et al. (2016), la población se define como “un grupo de individuos o elementos que son el foco de interés en una investigación, de los cuales se busca obtener información”.

Para la muestra de esta investigación, se seleccionó las 17 estructuras de la línea de transmisión antes mencionada. Todas las estructuras fueron consideradas para el desarrollo de las pruebas y evaluaciones correspondientes a la inspección de los aisladores (ver anexo 2).

El muestreo empleado en la investigación fue no probabilístico de tipo intencionado o por conveniencia. Campbell et al. (2020) indica que este tipo de muestreo permite seleccionar deliberadamente los elementos que aportan información relevante y útil para la investigación.

### **2.4. VARIABLES DE ESTUDIO**

- Deep Learning y dron
- Productividad

### 2.4.1.Operacionalización de variables

**Tabla 1**

*Operacionalización de Variables*

	<b>Descripción conceptual</b>	<b>Descripción operacional</b>	<b>Instrumentos</b>	<b>Indicadores</b>	<b>Escala de medición</b>
<b>Deep Learning y dron</b>	El Deep Learning permite que los modelos computacionales, formados por varias capas de procesamiento, adquieran representaciones de datos con diversos niveles de abstracción. Estas técnicas han avanzado significativamente el arte en el reconocimiento visual de objetos (LeCun et al, 2015).	Implementación de un modelo de Deep Learning para la detección de fallas en aisladores mediante el uso de dron, que recopilarán y procesarán imágenes.	- Software de Deep Learning - Dron	- Numero de fallas - Precisión	Numérica
<b>Productividad</b>	Se define al rendimiento o eficiencia de un proceso mediante el cual un trabajador, un grupo de personas o una maquina produce una cantidad especifica de bienes o finalizan un conjunto determinado de tareas en un periodo de tiempo (Personio, 2024).	La cantidad de producción, costos y tiempo se medirá mediante la comparación de la inspección tradicional y la inspección con aplicación de Deep Learning y dron.	- Excel -Entrevista estructurada	-Tiempo de inspección - costo operativo	Numérica

## **2.5. MÉTODOS**

### **2.5.1. Método de investigación**

El método de la investigación fue deductivo, dado a que partió de teorías o principios generales para su aplicación en una situación específica. De acuerdo con Pita y Pértigas (2002), afirma que el método deductivo se vincula a la investigación cuantitativa, ya que este enfoque se centra en analizar la relación o conexión entre variables que han sido cuantificadas.

### **2.5.2. Tipo de investigación**

La investigación desarrollada utilizó una metodología de tipo aplicada, aprovechando herramientas tecnológicas que permitieron una implementación precisa del modelo Deep Learning y generaron conocimiento con aplicación directa para la resolución del problema planteado. Según Lozada (2014), la investigación aplicada busca el conocimiento con la aplicación directa a los problemas de la sociedad o el sector productivo, apoyándose en la investigación básica y enfocándose en vincular la teoría con su aplicación práctica.

### **2.5.3. Enfoque o nivel de investigación**

La investigación adoptó un enfoque cuantitativo, ya que mediante la recolección de datos numéricos y análisis estadísticos buscó probar la hipótesis planteada, es decir, determinar si el uso del Deep Learning y dron aumentó la productividad en la detección de fallas en aisladores de la línea de transmisión y su comparación con los métodos tradicionales de inspección. Conforme a Surday (2007), la investigación cuantitativa se centra en recolectar, procesar y analizar datos numéricos sobre variables previamente definidas.

### **2.5.4. Diseño de investigación**

El diseño de la investigación fue no experimental, dado que no se manipularon las variables para evaluar el impacto del Deep Learning y dron en la productividad. Según Agudelo et al (2010), este tipo de diseño no implica manipulación de las variables independientes, es decir, no se crea una situación experimental controlada para observar los efectos de una variable sobre otra.

## 2.6. TÉCNICAS E INSTRUMENTOS

### 2.6.1. Entrevista

Se empleó la entrevista como técnica para recolectar información. Según Díaz et al (2013), la entrevista es una interacción comunicativa planificada cuyo propósito es obtener información específica, más allá de una conversación informal.

### 2.6.2. Guía de entrevista estructurada

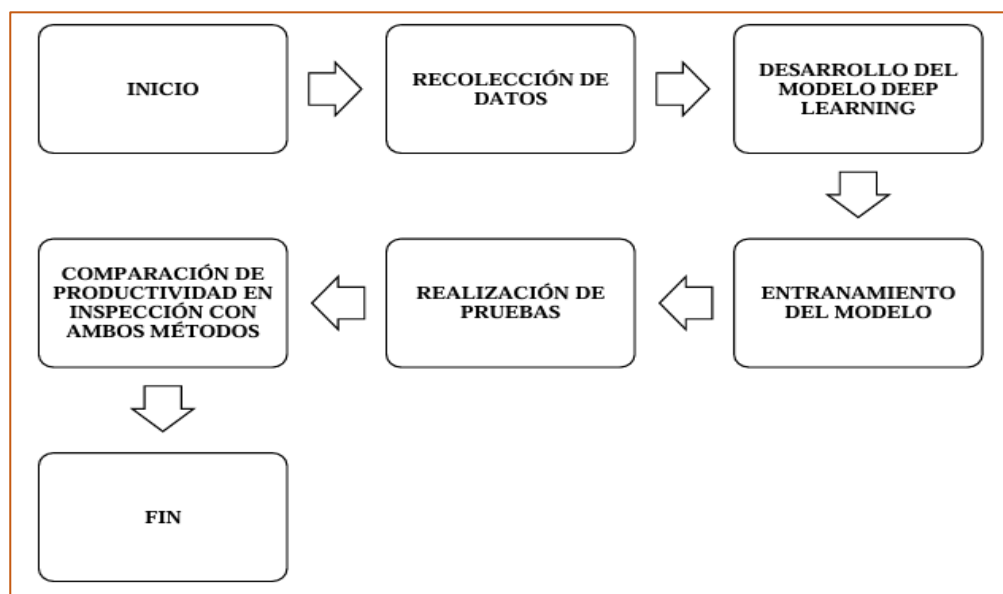
En esta investigación se utilizó como instrumento la guía de entrevista estructurada (ver anexo 3). Díaz et al. (2013) señala que consiste en un conjunto de preguntas predeterminados que se presentan en un orden específico orientadas a recolectar información precisa, uniforme y comparable al aplicar las mismas preguntas a todos los entrevistados.

### 2.6.3. Validez y confiabilidad

La guía de entrevista estructurada fue validada por tres expertos en la especialidad, el cual se registró con sus firmas para dar confiabilidad al instrumento de recolección de datos (ver anexo 4).

### Figura 2

Diagrama del procedimiento de la investigación



Fuente: Elaboración propia

## 2.7. PROCEDIMIENTO

### 2.7.1. Equipos y Materiales

Para llevar a cabo la recolección de información mediante métodos tradicionales, así como técnicas de Deep Learning y dron, fue necesario disponer con diversos equipos y materiales.

**Tabla 2**

*Equipos y Materiales*

MÉTODO TRADICIONAL	MÉTODO DE DEEP LEARNIN Y DRON
- Celular	- Dron Phantom 4 RTK
- Equipo de protección personal	- Control remoto
- Hoja de inspección	- Baterías y cargadores
	- Tarjeta de memoria
	- Laptop Intel Core i7
	- Memoria USB

*Nota.* En la tabla se detallan los equipos y materiales requeridos para la implementación de la metodología tradicional, así como la metodología de Deep Learning y dron.

### 2.7.2. Recolección de datos del procedimiento actual de inspección y detección de fallas de aisladores en líneas de transmisión

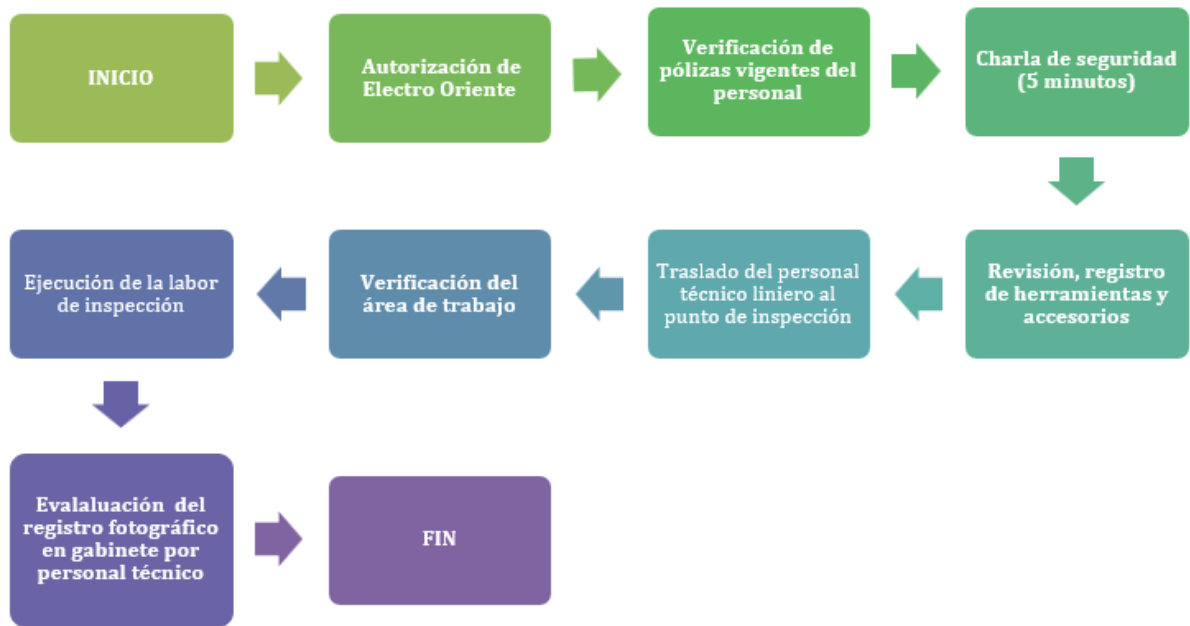
#### Descripción del proceso de inspección con el método tradicional

Antes de iniciar con los trabajos de inspección programados por la empresa colaboradora, se requiere contar con la autorización de la empresa concesionaria Electro Oriente. El personal técnico debe contar con pólizas vigentes y participar en una charla de seguridad previa de cinco minutos. Asimismo, se realiza la revisión de las herramientas y accesorios a utilizar, con el fin de evitar los retrasos en la ejecución de labores, registrándose además las salidas correspondientes.

Posteriormente, el personal técnico se desplaza a los puntos de inspección, donde verifica el área de trabajo con el propósito de identificar peligros y riesgos, estableciendo las medidas preventivas necesarias para el adecuado desarrollo de las actividades. El personal técnico, debe contar con la información técnica, y los puntos de cada estructura georreferenciados en Google Earth para facilitar su ubicación en campo.

**Figura 3**

*Diagrama del proceso de inspección con el método tradicional*




Fuente: Elaboración propia.

La inspección se realiza desde la base de la torre, estando prohibido el ascenso por las estructuras o la aproximación a los conductores. Las actividades consisten principalmente en una inspección visual desde el suelo, para la identificación del estado físico de los aisladores. En caso de detectarse anomalías críticas o de condiciones que representen un riesgo potencial para las personas o las instalaciones, el personal técnico deberá informar de inmediato a sus supervisores.

Cada estructura inspeccionada debe contar con un registro fotográfico realizado con un dispositivo celular, que incluya vista general de la estructura, vista panorámica, y fotografías de todos los aisladores. Posteriormente, este material es evaluado en gabinete por personal técnico a fin de determinar el estado de los aisladores.

## Figura 4

### *Inspección tradicional de las líneas de transmisión*



Fuente: Fotografía tomada por personal técnico durante una inspección de campo. Jaén (2025).

Las inspecciones de las estructuras de las líneas de transmisión se realizan con una frecuencia trimestral. Para la obtención de los datos del presente estudio, se utilizó la información recabada mediante una entrevista estructurada a un técnico liniero y al supervisor de la empresa colaboradora Consorcio Eléctrico Jaén, responsable del mantenimiento de líneas de transmisión y subestaciones de potencia.

La entrevista se desarrolló de manera presencial, registrándose las repuestas mediante anotaciones directas en el instrumento de preguntas estructuradas, con el fin de garantizar la precisión y coherencia de la información obtenida (ver anexo 4).

El cuestionario aplicado constó de ocho preguntas, de las cuales las seis primeras se dirigieron al técnico, orientadas al procedimiento actual de inspección, número de técnicos requeridos, tiempo promedio de inspección, cantidad de inspecciones diarias y los riesgos asociados.

De acuerdo con la información proporcionada por los entrevistados, se presenta un resumen de la información obtenida:

**Tabla 3***Información obtenida en la entrevista*

<b>Aspecto evaluado</b>	<b>Información obtenida</b>
Método de inspección	Visual, desde el suelo.
Cuadrilla de inspección	2 técnicos, 2 apoyos y 1 conductor - Técnicos: inspección visual y fotografías desde la base con cámara de celular.
Función del personal	- Apoyos: limpieza de servidumbre y base de la estructura. - Conductor: traslado de la cuadrilla.
Tomas fotográficas	Vista panorámica, vista general de la torre, aisladores.
Tiempo promedio de inspección por torre	De 23 minutos
Cantidad de inspección por día	De 8 a 10 torres. - Técnicos: S/. 100/día. - Apoyos: S/. 60/día.
Costos operativos	- Conductor: S/.53.33/día. - Combustible: S/. 50/día. - Viáticos: S/. 50/día (almuerzo).

*Nota.* Información obtenida en la entrevista a un técnico liniero y al supervisor de la empresa colaboradora de Electro Oriente, Consorcio Eléctrico Jaén.

### **2.7.3. Desarrollo del modelo Deep Learning para detección automática de fallas en aisladores**

Con el fin de cumplir con el segundo objetivo específico, se desarrolló un modelo de aprendizaje profundo (Deep Learning) para la detección automática de fallas en aisladores, utilizando imágenes obtenidas mediante un vehículo aéreo no tripulado (VANT o dron).

A diferencia del método tradicional, la inspección con dron permitió recorrer visualmente las estructuras desde distintos ángulo y alturas, capturando imágenes de alta resolución sin necesidad de acercamiento físico del personal técnico a las torres, abarcando las 17 estructuras que conforman la línea de transmisión SE Nueva Jaén - SE Jaén.

Para el proceso de inspección mediante vehículo aéreo no tripulado (VANT), se contó con el apoyo de la Universidad Nacional de Jaén, quien mediante un préstamo formal facilitó el dron Phantom 4 RTK y un vehículo institucional para su traslado.

#### **Tabla 4**

##### *Características del dron Phantom 4RTK*

<b>Descripción</b>	<b>Características</b>
Peso de despegue	1391 gramos
Altura máx. de servicio	6000 m
Velocidad máx. de ascenso	5m/s control manual
Velocidad máx. de descenso	3m/s
Tiempo máximo de vuelo	Aprox. 30 minutos
Cámara	CMOS de 1”; pixeles efectivos: 20M

*Nota.* El cuadro muestra las características del dron utilizado en la inspección. Adaptado de DJI Agriculture, 2025. <https://ag.dji.com/phantom-4-rtk/specs>

Previo al desarrollo de la inspección, se gestionó la autorización correspondiente con la empresa concesionaria Electro Oriente (ver anexo 5). Se coordinó con el técnico operador del dron para la planificación del trabajo en campo.

La planificación del vuelo se realizó de manera sistemática para garantizar la seguridad operativa y la calidad de los datos. Se verificó un área amplia y libre de obstáculos para el despegue, se ensambló el equipo asegurando la correcta fijación de las hélices y se verificó que las baterías del dron y del control remoto estuvieran completamente cargadas.

A continuación, se encendieron ambos dispositivos, se comprobó su conexión mediante la aplicación DJI Go y se confirmó la disponibilidad de un número suficiente de satélites para garantizar un despegue seguro. En este caso, el vuelo fue ejecutado de forma manual, siendo el piloto el operador quien controló directamente el dron durante toda la operación.

## **Figura 5**

### *Fijación de hélices y batería*



Fuente: Elaboración propia

## **Figura 6**

### *Realización de la inspección con dron*



Fuente: Elaboración propia

Durante la operación, el dron se posicionó a una distancia aproximada de 8 metros de los aisladores, debido a que la presencia del campo eléctrico generado por la línea de 60 kV ocasionaba la activación de alarmas de alta interferencia en la aplicación de control de vuelo, con el riesgo asociado de pérdida de comunicación si se aproximaba aún más a la línea. Asimismo, se procuró ubicar el dron en el ángulo más favorable para la captura de imágenes, evitando su orientación en contra de la fuente de iluminación natural, a fin de preservar la nitidez y el detalle de los aisladores durante el registro fotográfico (ver figura 6)

## **Figura 7**

*Toma de fotografías con el Dron Phantom 4 RTK*



Fuente: Elaboración propia

### **a) Tiempos de inspección con el VANT o dron.**

Con el objetivo de registrar la eficiencia operativa del proceso, se realizó la medición de los tiempos de vuelo y traslado por cada estructura inspeccionada. En cada punto de la línea de transmisión, el operador ejecutó un ciclo completo de preparación, vuelo, aterrizaje y desplazamiento hacia la siguiente estructura. La tabla 5 muestra los tiempos promedios obtenidos durante las 17 inspecciones efectuadas.

**Tabla 5***Tiempos operativos por estructura en la inspección*

N° de estructura	Preparación y verificación (min)	Vuelo e inspección (min)	Aterrizaje (min)	Traslado a la siguiente estructura (min)	Tiempo total (min)
1	2	4.0	1	3	10.0
2	2	3.8	1	2	8.8
3	2	4.2	1	3	10.2
4	2	4.1	1	4	11.1
5	2	3.9	1	3	9.9
6	2	4.3	1	2	9.3
7	2	4.0	1	3	10.0
8	2	4.1	1	4	11.1
9	2	3.7	1	3	9.7
10	2	4.5	1	3	10.5
11	2	4.2	1	2	9.2
12	2	3.8	1	3	9.8
13	2	4.1	1	2	9.1
14	2	4.0	1	3	10.0
15	2	3.9	1	4	10.9
16	2	4.2	1	3	10.2
17	2	4.0	1	-	7.0
<b>Tiempo promedio por estructura (min)</b>					<b>9.9</b>

Nota. Elaboración propia (2025). Los tiempos fueron estimados con base en mediciones de campo durante la inspección con dron Phantom 4RTK en la línea de Transmisión SE Nueva Jaén – SE Jaén.

El tiempo total para la inspección de las 17 estructuras fue de (168.3 minutos), es decir 2 horas y 48 minutos. Considerando el tiempo promedio de 9.9 minutos por estructura mostrado en la Tabla 5 y una jornada laboral efectiva de siete horas (420 minutos), descontando una hora destinada al almuerzo, se estima que es posible inspeccionar aproximadamente 42 estructuras por jornada utilizando el dron Phantom 4 RTK.

## b) Costo por inspección con VANT o Dron

El costo diario estimado para la inspección se detalla en la tabla 6, donde se incluye la participación del operador de dron, técnico liniero, conductor, viáticos, combustible.

**Tabla 6**

*Costos por la inspección diaria con dron Phantom 4RTK*

<b>Descripción</b>	<b>unidad</b>	<b>Cantidad</b>	<b>Precio unitario (soles)</b>	<b>Precio total (soles)</b>
Operador del dron	Dia	1	150.00	150.00
Técnico liniero	Dia	1	100.00	100.00
Conductor	Dia	1	53.33	53.33
Viáticos(almuerzo)	Dia	1	10.00	30.00
Combustible	Dia	1	50.00	50.00
<b>Costo total de inspección</b>				<b>383.33</b>

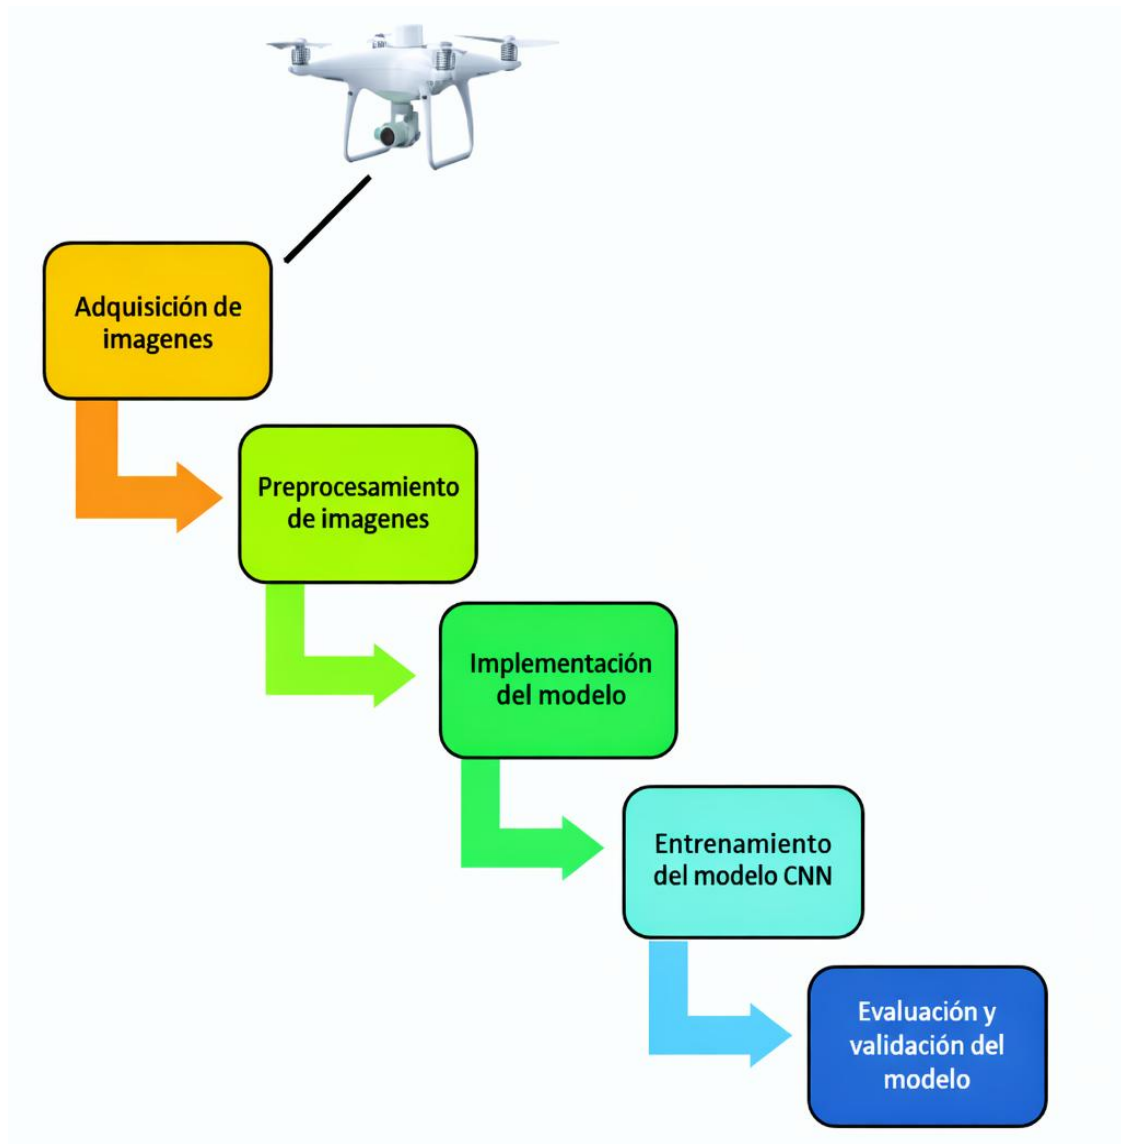
Nota. Elaboración propia.

## Modelo Deep Learning

A continuación, se muestra el flujo de trabajo seguido para el desarrollo del modelo, desde la obtención de imágenes hasta la presentación de resultados. Este proceso se compone de varias etapas secuenciales que permiten estructurar y automatizar la detección de fallas en aisladores.

**Figura 8**

*Diagrama del modelo Deep Learning*



Fuente: Elaboración propia

### **Adquisición de imágenes**

Durante el proceso de inspección el dron sobrevoló las líneas de transmisión y registró fotografías detalladas de los aisladores. Estas imágenes son posteriormente transferidas al gabinete, donde son procesadas con el modelo Deep Learning implementado el cual permite clasificar y detectar automáticamente los posibles fallos de los aisladores como suciedad, rotos, flameados o en buen estado.

## **Base de datos**

La base de datos fue construida a partir de imágenes de aisladores capturadas mediante inspecciones, empleando el Dron Phantom 4 RTK, con el objetivo de obtener fotografías claras y representativas de los aisladores (Buenos, Sucios, Rotos/ Flameados). Durante la adquisición de imágenes, se procuró evitar patrones de color similares al aislador, como piedras, cielo o techos, para facilitar la detección y extracción posterior de características relevantes.

Debido a la escasez de aisladores con daños o contaminación en la línea de transmisión SE Nueva Jaén – SE Jaén, se complementó la base de datos con imágenes provenientes de Dataset Públicos. Estas fuentes permitieron enriquecer el conjunto de entrenamiento con una mayor diversidad de condiciones ambientales, tipos de aisladores y patrones de daños.

Se recolectaron 2016 imágenes de fallas de diferentes aisladores, conformado por 981 imágenes de aisladores buenos, 330 imágenes de aisladores sucios y 705 imágenes de aisladores rotos/flameados, lo cual conformó la base de datos inicial.

Los aisladores buenos fueron aquellos que no presentaron fallas visibles ni anomalías en su superficie, manteniendo su integridad tanto eléctrica como mecánica. Visualmente, exhibieron una superficie limpia y uniforme, sin acumulación significativa de contaminantes, fisuras, fracturas o desprendimientos, y conservaron la textura y el color propios de su material de fabricación. En este estado, los aisladores cumplieron de manera confiable con la función de resistir esfuerzos mecánicos y conservar la rigidez dieléctrica para la cual habían sido diseñados, constituyendo la referencia de comparación frente a los aisladores deteriorados.

**Figura 9**

*Base de datos de aisladores buenos*



Fuente: Elaboración propia

Los aisladores sucios presentaron acumulación de suciedad, contaminantes en su superficie, lo que afectó su capacidad de aislamiento eléctrico y aumentó el riesgo de fallas en la línea de transmisión. Estas condiciones deterioraron el desempeño del aislador y requirieron una detección precisa para su mantenimiento y reparación oportunos.

**Figura 10**

*Base de datos de aisladores sucios*

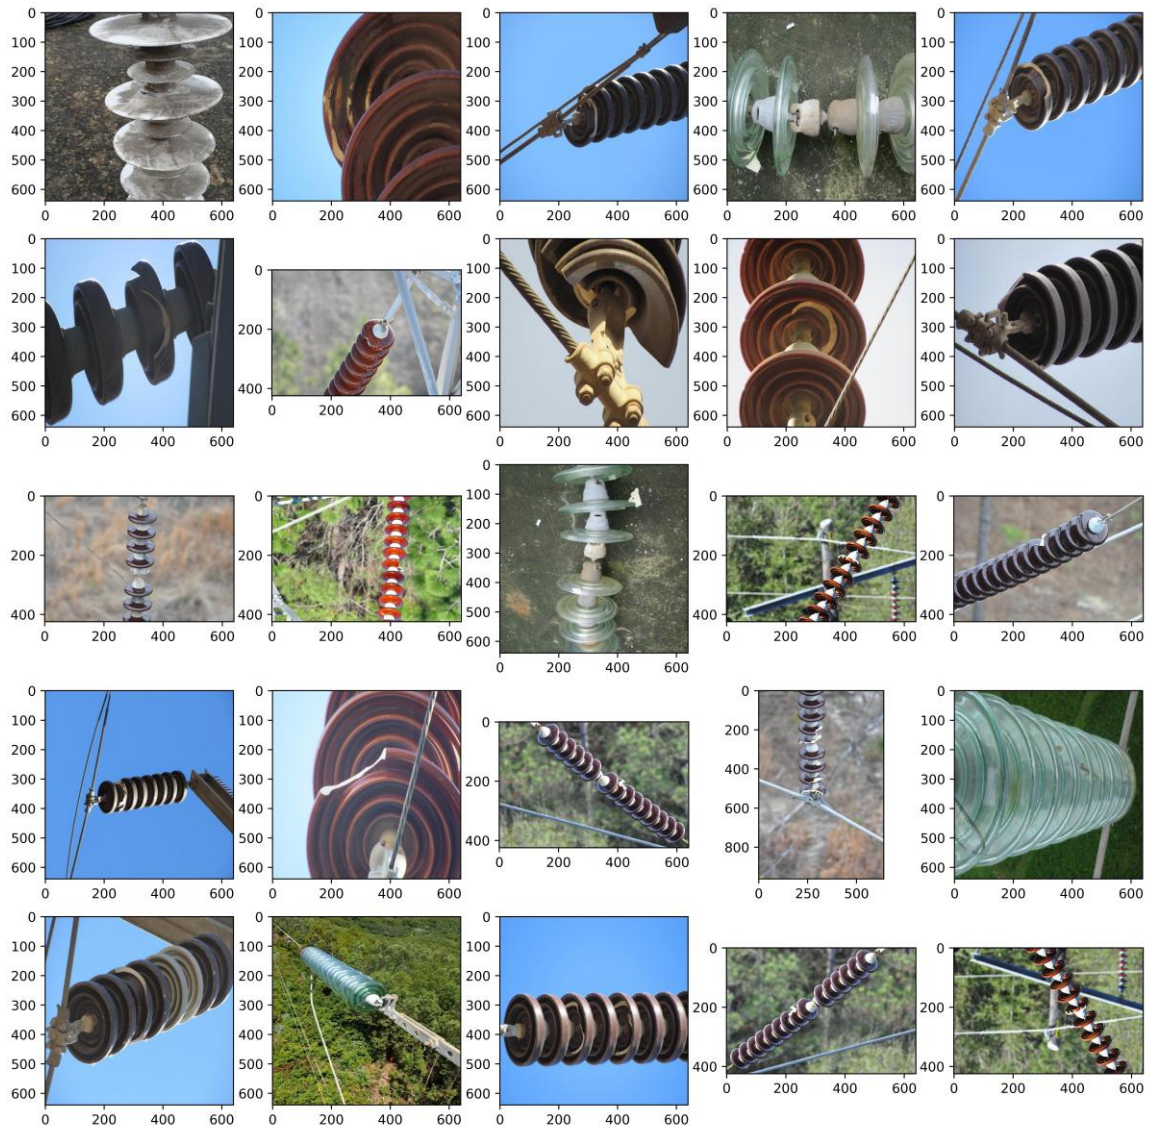


Fuente: Elaboración propia

La base de datos de aisladores rotos/flameados estuvo conformada por imágenes que mostraron daños visibles en la estructura de los aisladores, tales como fracturas, fisuras o marcas de quemaduras superficiales. Estos defectos comprometieron tanto la integridad mecánica como la capacidad de aislamiento eléctrico, incrementando el riesgo de fallas en la línea de transmisión.

**Figura 11**

*Base de datos de aisladores rotos/flameados*



Fuente: Elaboración propia

### **Preprocesamiento de imágenes**

Se realizó una optimización y estandarización de la base de datos, empleando Python 3.9 en Google Colab. Cada imagen fue convertida a formato JPEG y al espacio de color RGB, asegurando compatibilidad con los algoritmos de visión artificial, y se preservaron los metadatos EXIF cuando fue posible para mantener información relevante de la captura (Beleño Díaz et al., 2020). Posteriormente, se realizó la optimización de resolución y

calidad, ajustando el ancho máximo de las imágenes a 640 píxeles y aplicando técnicas de compresión sin pérdida significativa de detalle visual, garantizando uniformidad.

Adicionalmente, se generaron subconjuntos representativos mediante selección aleatoria y redimensionamiento proporcional a 640 píxeles de ancho, manteniendo la relación de aspecto y renombrando sistemáticamente los archivos para facilitar su organización y etiquetado según las clases de aisladores: buenos, sucios/flameados y rotos. Estas acciones permitieron construir un conjunto de datos homogéneo, balanceado y representativo, optimizando el rendimiento de los modelos de aprendizaje automático y asegurando la conservación de las características esenciales para la correcta clasificación de los aisladores.

La base de datos final estuvo compuesta por un total de 2239 imágenes, distribuidas entre las distintas categorías: 1069 imágenes de aisladores buenos, 660 imágenes de aisladores sucios y 510 correspondiente a aisladores rotos/flameados.

## **Desarrollo del modelo Deep Learning**

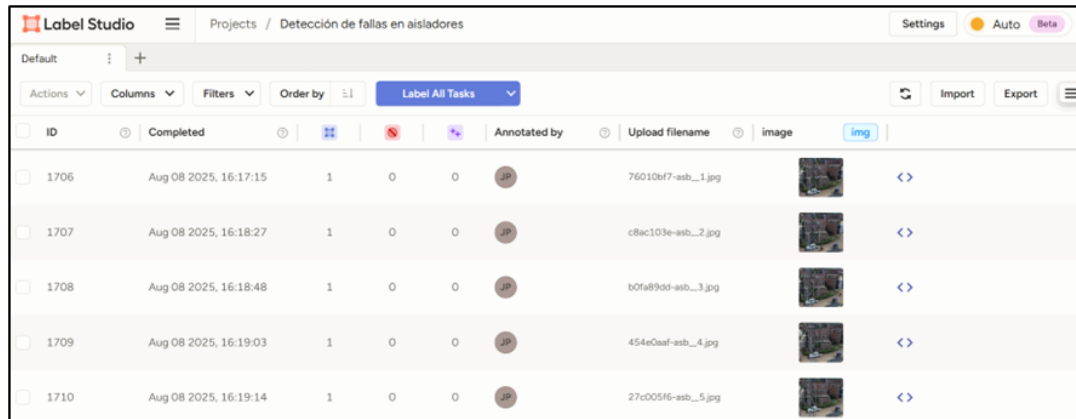
### **Etiquetado de las clases**






El proceso de etiquetado de las imágenes se realizó utilizando la herramienta de código abierto Label Studio 1.20.0, ampliamente empleada en proyectos de visión por computadora por su flexibilidad y compatibilidad con múltiples formatos de anotación (Tkachenko et al., 2025).

Se creó un nuevo proyecto dentro de la plataforma, seleccionando la plantilla Object Detection with Bounding Boxes en el Labeling Interface. Posteriormente se configuraron tres clases: Aislador Bueno, Aislador Sucio/Flameado y Aislador Roto. Luego, se importó el conjunto de imágenes en formato JPG previamente preprocesadas, asegurando que cada archivo mantuviera un nombre único para evitar inconsistencias.

## Figura 12

### Creación del proyecto en Label-Studio




ID	Completed	Annotated by	Upload filename	image
1706	Aug 08 2025, 16:17:15	JP	76010bf7-asb_1.jpg	
1707	Aug 08 2025, 16:18:27	JP	c8ac103e-asb_2.jpg	
1708	Aug 08 2025, 16:18:48	JP	b0fa89dd-asb_3.jpg	
1709	Aug 08 2025, 16:19:03	JP	454e0aaf-asb_4.jpg	
1710	Aug 08 2025, 16:19:14	JP	27c005f6-asb_5.jpg	

Fuente: Elaboración propia

Durante la fase de anotación, se emplearon cajas delimitadoras (bounding boxes) para identificar de forma precisa la ubicación de cada aislador en la imagen, asignando a cada región la etiqueta correspondiente según su estado. Este procedimiento se llevó a cabo de manera manual, garantizando la calidad y coherencia de las anotaciones. Para reducir el sesgo humano, se implementó un proceso de revisión cruzada, en el cual un segundo anotador validó aleatoriamente un subconjunto de imágenes para verificar la consistencia de la clasificación.

## Figura 13

### Etiquetado de las imágenes mediante cajas delimitadoras

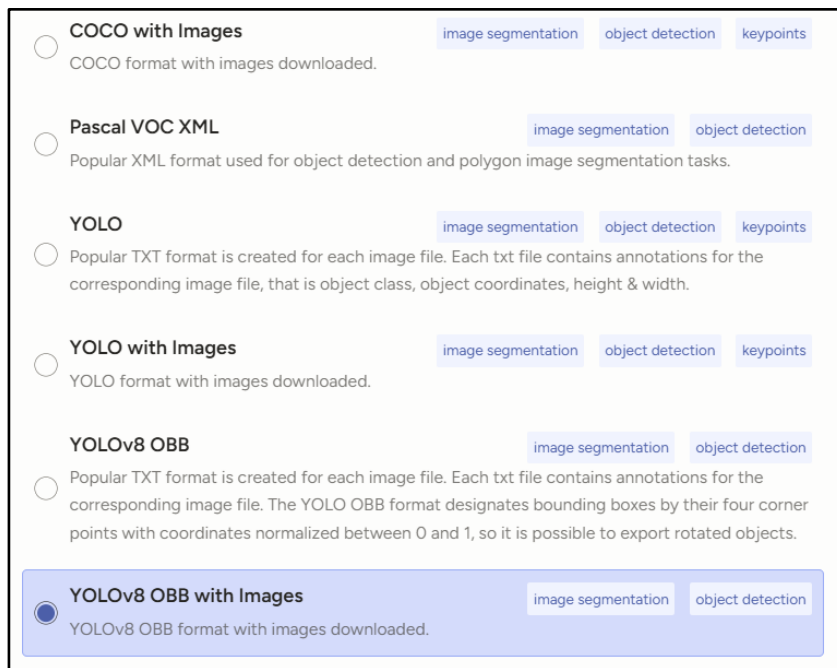


Fuente: Elaboración propia

Finalmente, las anotaciones fueron exportadas en formato YOLO, generando para cada imagen un archivo de texto que contenía la clase, las coordenadas normalizadas del centro de la caja delimitadora, así como su ancho y alto relativo a la imagen. Este formato resultó óptimo para su integración directa en el entrenamiento del modelo YOLOv11, garantizando compatibilidad y facilitando la automatización del flujo de trabajo.

### Figura 14

Exportación de la base de datos para YOLO v11



Fuente: Elaboración propia

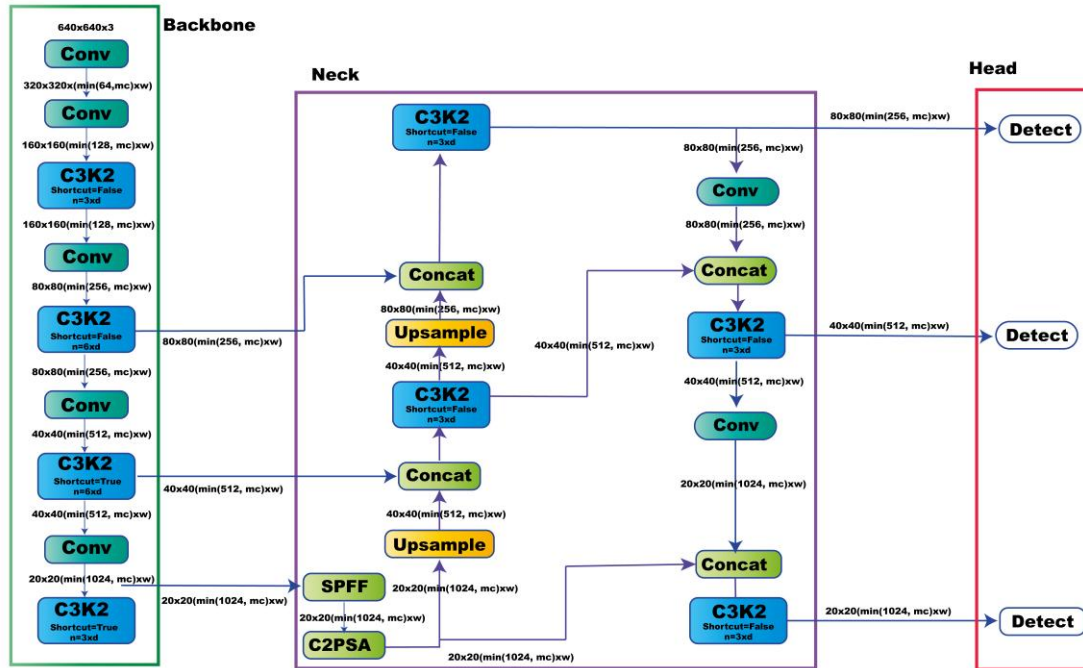
### Modelo Yolo V11

Se utilizó el algoritmo YOLO (You Only Look Once) una arquitectura con convoluciones separables profundas, estructura de embotellamiento residual inverso y un mecanismo de atención ligero, con el objetivo de reducir el costo computacional y aumentar la velocidad de detección sin comprometer la precisión (Q. Wang et al., 2024). Esta red neuronal convolucional se distingue de otros métodos por su capacidad para predecir múltiples clases dentro de una única imagen mediante el uso de cuadros delimitadores, analizando de manera integral las características presentes en la imagen (J. Liu et al., 2021). El modelo fue diseñado para procesar imágenes de alta resolución de manera eficiente, distinguiendo automáticamente entre las clases buenos, sucios/flameados y rotos,

optimizando así los tiempos de inferencia y facilitando su aplicación en entornos de inspección eléctrica en campo.

**Figura 15**

*Estructura de Yolo v11*




Fuente: Elaboración propia

YOLO v11 segmenta la imagen de entrada en una cuadrícula de tamaño  $S \times S$ , determinada en función de la resolución de la imagen. Cada celda de la cuadrícula se encarga de estimar la probabilidad de que un objeto se encuentre dentro de su área correspondiente. La predicción generada por cada celda está compuesta por cinco elementos fundamentales: las coordenadas (x, y) que indican la posición del objeto, las dimensiones (w, h) que representan su tamaño, y un valor de confianza que refleja la certeza de la detección (Stefenon et al., 2025).

**Figura 16**

*Segmentación de la imagen en cuadrículas de tamaño SxS*



Fuente: Elaboración propia

El modelo se programó empleando la librería de Ultralytics v0.0.6, el cual ofrece una implementación optimizada y de alto rendimiento del algoritmo YOLOv11 (Ver Tabla 7). El proceso comenzó con la carga de un modelo preentrenado (yolo11n.pt y yolos.pt), que sirvió como base para el aprendizaje por transferencia, aprovechando el conocimiento adquirido en grandes bases de datos de imágenes (Khanam & Hussain, 2024).

**Tabla 7***Modelos de YOLOv11*

<b>Modelo</b>	<b>Tamaño (px)</b>	<b>mAPval 50-95</b>	<b>Velocidad CPU ONNX (ms)</b>	<b>Velocidad T4 TensorRT10 (ms)</b>	<b>Parámetros (M)</b>
YOLO11n	640	39.5	56.1 ± 0.8	1.5 ± 0.0	2.6
YOLO11s	640	47.0	90.0 ± 1.2	2.5 ± 0.0	9.4
YOLO11m	640	51.5	183.2 ± 2.0	4.7 ± 0.1	20.1
YOLO11l	640	53.4	238.6 ± 1.4	6.2 ± 0.1	25.3
YOLO11x	640	54.7	462.8 ± 6.7	11.3 ± 0.2	56.9

*Nota.* Rendimiento del modelo YOLO11. Adaptado de Ultralytics YOLOv11.

<https://docs.ultralytics.com/es/models/yolo11/>

Posteriormente se definió un tamaño de imagen de 640 píxeles como dimensión máxima de entrada, equilibrando el detalle espacial con la eficiencia computacional. Además, se habilitó la generación automática de gráficos de entrenamiento, lo que permitió monitorear en tiempo real la evolución de métricas como la pérdida de clasificación, la pérdida de localización de los cuadros delimitadores y el desempeño general del modelo.

En Python se importó la librería `from ultralytics import YOLO` y se cargó el modelo (`model = YOLO("yolo11n.pt")`). Posteriormente, se ejecutó el procedimiento de entrenamiento mediante el comando `model.train()`, especificando los parámetros fundamentales del proceso:

**Data:** `"/content/datasets/data.yaml"` para indicar la ruta del archivo de configuración de la base de datos, que contenía la definición de las clases y las rutas de las imágenes de entrenamiento, validación y prueba.

**Epochs:** Se agregaron 50 épocas, determinando el número de iteraciones completas sobre el conjunto de datos, suficientes para lograr convergencia sin incurrir en sobreajuste.

**Imgsz:** 640x640 píxeles, que fijó el tamaño máximo de las imágenes de entrada, balanceando resolución y eficiencia computacional.

**Plots:** `True`, habilitando la generación de gráficos de evolución de métricas de pérdida y precisión, útiles para monitorear el comportamiento del modelo en tiempo real.

## Figura 17

Definición del modelo en Python

```

from ultralytics import YOLO

# Cargar el modelo
model = YOLO("yolo11n.pt")

# Entrenar el modelo
results = model.train(data="/content/datasets/data.yaml",
                      epochs=50, # Número de iteraciones
                      imgsz=640, # Tamaño de las imágenes (máxima dimensión)
                      plots=True, # Guardar gráficos de entrenamiento
                      )

```

Fuente: Elaboración propia

**Tabla 8**

Estructura de Yolo v11

From	Params	Module	Arguments
-1	928	ultralytics.nn.modules.conv.Conv	[3, 32, 3, 2]
-1	18560	ultralytics.nn.modules.conv.Conv	[32, 64, 3, 2]
-1	26080	ultralytics.nn.modules.block.C3k2	[64, 128, 1, False, 0.25]
-1	147712	ultralytics.nn.modules.conv.Conv	[128, 128, 3, 2]
-1	103360	ultralytics.nn.modules.block.C3k2	[128, 256, 1, False, 0.25]
-1	590336	ultralytics.nn.modules.conv.Conv	[256, 256, 3, 2]
-1	346112	ultralytics.nn.modules.block.C3k2	[256, 256, 1, True]
-1	118067	ultralytics.nn.modules.conv.Conv	[256, 512, 3, 2]
	2		
-1	138035	ultralytics.nn.modules.block.C3k2	[512, 512, 1, True]
	2		
-1	656896	ultralytics.nn.modules.block.SPPF	[512, 512, 5]
-1	990976	ultralytics.nn.modules.block.C2PS	[512, 512, 1]
		A	
-1	0	torch.nn.modules.upsampling.Upsample	[None, 2, 'nearest']
[-1, 6]	0	ultralytics.nn.modules.conv.Concat	[1]
-1	443776	ultralytics.nn.modules.block.C3k2	[768, 256, 1, False]

-1	0	torch.nn.modules.upsampling.Upsample	[None, 2, 'nearest']
[-1, 4]	0	ultralytics.nn.modules.conv.Concat	[1]
-1	127680	ultralytics.nn.modules.block.C3k2	[512, 128, 1, False]
-1	147712	ultralytics.nn.modules.conv.Conv	[128, 128, 3, 2]
[-1, 13]	0	ultralytics.nn.modules.conv.Concat	[1]
-1	345472	ultralytics.nn.modules.block.C3k2	[384, 256, 1, False]
-1	590336	ultralytics.nn.modules.conv.Conv	[256, 256, 3, 2]
[-1, 10]	0	ultralytics.nn.modules.conv.Concat	[1]
-1	1511424	ultralytics.nn.modules.block.C3k2	[768, 512, 1, True]
[16, 19, 22]	820569	ultralytics.nn.modules.head.Detect	[3, [128, 256, 512]]

---

## Entrenamiento y Validación del Modelo

Durante la fase de entrenamiento, se utilizaron técnicas de aumento de datos (data augmentation), incluyendo rotaciones, traslaciones, espejado horizontal y vertical, así como ajustes de brillo y contraste, con el objetivo de mejorar la robustez del modelo frente a variaciones en iluminación, ángulo de captura y condiciones ambientales (Potnuru, 2016). Estas transformaciones permitieron aumentar la diversidad del conjunto de entrenamiento sin necesidad de recopilar imágenes adicionales en campo. La base de datos se dividió en un conjunto de entrenamiento de 1720 imágenes (70%) y un conjunto de validación de 430 imágenes (30%).

Luego, el modelo fue ajustado a la base de datos mediante un entrenamiento supervisado, utilizando el archivo de configuración data.yaml, que contenía la estructura de las clases y las rutas de las imágenes para entrenamiento, validación y prueba. El entrenamiento se realizó durante 50 épocas, un número adecuado para alcanzar la convergencia sin incurrir en sobreajuste.

## Figura 18

Creación del archivo YAML con las clases

```
import os
import yaml

# Datos para el YAML
data = {
    'path': '/content/datasets',
    'train': 'images/train',
    'val': 'images/val',
    'test': 'images/test',
    'names': {
        0: "Bueno",
        1: "Roto/Flameado",
        2: "Sucio"
    }
}

# Crear carpeta
os.makedirs('/content/datasets', exist_ok=True)

# Guardar el YAML
with open('/content/datasets/data.yaml', 'w') as file:
    yaml.dump(
        data,
        file,
        default_flow_style=False,
        sort_keys=False
    )
```

Fuente: Elaboración propia

Posteriormente, se llevó a cabo el entrenamiento supervisado sobre la base de datos, configurada mediante el archivo data.yaml, el cual contenía la definición de las tres clases (buenos, sucios/flameados y rotos) y las rutas a los conjuntos de imágenes de entrenamiento, validación y prueba. El proceso se ejecutó durante 50 épocas, con un tamaño máximo de imagen de 640 píxeles, lo que representó un balance entre detalle visual y costo computacional.

### Configuración de la Red

Se utilizó el sistema operativo Windows 11; la GPU es NVIDIA RTX 3070ti con 8 G de memoria de vídeo; la CPU es Intel i7, empleando PyTorch 2.0.0, Python 3.9.13 y CUDA 11.1. Para garantizar una gran eficacia del entrenamiento, se establecieron los siguientes hiperparámetros:

**Batch size:** Para el entrenamiento, se empleó un batch size de 14. Esto significa que 14 imágenes serán utilizadas por iteración, para actualizar los parámetros de la CNN.

**Momentum:** Es un parámetro que permitio minimizar los cambios en los pesos entre lotes, ya que solo se procesa una pequeña porción de la imagen en cualquier momento.

**Learning rate:** Indica que tan rapido un batch está aprendiendo. El valor asignado para la red fue de 0.01.

**Tabla 9**

*Parámetros del modelo*

Parámetros	Valores
Image sizes	640x640
Optimizer	Adam
Epoch	50
Batch size	14
Learning rate	0.01
Weight decay	0.0005
Momentum	0.937

*Nota.* Parámetros del modelo realizado

La tasa de aprendizaje inicial del entrenamiento se fijó en 0.01; el lote de entrenamiento en 14; el coeficiente de decaimiento del peso en 0.0005; el coeficiente de impulso se fijó en 0.937; y las rondas de iteración se configuraron en 50.

**Figura 19**

*Entrenamiento del modelo Yolo v11*

```
Plotting labels to runs/detect/train/labels.jpg...
optimizer: 'optimizer=auto' found, ignoring 'lr=0.01' and 'momentum=0.937' and determining best 'optimizer', 'lr' and 'momentum' automatically...
optimizer: AdamW(lr=0.001429, momentum=0.9) with parameter groups 81 weight(decay=0.0), 88 weight(decay=0.0005), 87 bias(decay=0.0)
Image sizes 640 train, 640 val
Using 0 dataloader workers
Logging results to runs/detect/train
Starting training for 20 epochs...
```

Epoch	GPU_mem	box_loss	cls_loss	dfl_loss	Instances	Size
1/20	0G	1.424	2.519	1.452	13	640: 100% ██████████ 108/108 [07:28<00:00, 4.15s/it]
	Class	Images	Instances	Box(P)	R	mAP50 mAP50-95): 100% ██████████ 14/14 [00:57<00:00, 4.11s/it]
2/20	0G	1.434	1.819	1.444	22	640: 100% ██████████ 108/108 [07:34<00:00, 4.21s/it]
	Class	Images	Instances	Box(P)	R	mAP50 mAP50-95): 100% ██████████ 14/14 [00:51<00:00, 3.69s/it]
3/20	0G	1.487	1.647	1.465	15	640: 100% ██████████ 108/108 [07:33<00:00, 4.19s/it]
	Class	Images	Instances	Box(P)	R	mAP50 mAP50-95): 100% ██████████ 14/14 [00:49<00:00, 3.54s/it]
4/20	0G	1.436	1.467	1.442	20	640: 100% ██████████ 108/108 [07:40<00:00, 4.26s/it]
	Class	Images	Instances	Box(P)	R	mAP50 mAP50-95): 100% ██████████ 14/14 [00:59<00:00, 4.23s/it]
5/20	0G	1.445	1.265	1.422	25	640: 100% ██████████ 108/108 [07:42<00:00, 4.28s/it]
	Class	Images	Instances	Box(P)	R	mAP50 mAP50-95): 100% ██████████ 14/14 [00:47<00:00, 3.41s/it]

Fuente: Elaboración propia

## Evaluación del modelo

### Métricas de desempeño

Una vez finalizado el entrenamiento, el modelo fue evaluado utilizando el conjunto de validación, lo que permitió estimar de forma objetiva su capacidad de generalización. Las métricas empleadas fueron precisión, recall, F1-score y mAP (mean Average Precision). Estas métricas permitieron cuantificar la capacidad del modelo para identificar correctamente cada clase de aislador y discriminar entre casos positivos y negativos, garantizando su confiabilidad en aplicaciones de inspección automática en líneas de transmisión y distribución (J. Liu et al., 2021).

**Tabla 10**

*Matriz de confusión*

Valor Real	Predicción	
	Positivo	Negativo
Positive	Verdadero positivo (TP)	Falso negativo (FN)
Negative	Falso positivo (FP)	Verdadero negativo (VN)

*Nota.* La matriz de confusión muestra el desempeño del modelo al comparar las predicciones con los valores reales, indicando los aciertos y errores en la clasificación.

La matriz de confusión describe la concordancia entre la predicción y el estado real del de las clases predichas. Se define como verdadero positivo (TP) cuando la predicción del algoritmo y el estado real del objeto son positivos, y falso positivo (FP) cuando la predicción es verdadera. Aun así, el valor exacto del objeto es negativo, negativo verdadero (VN) cuando la predicción y el valor real del objeto son también falsos, y negativo falso (FN) cuando el algoritmo predice negativo. Aun así, el valor real del objeto es positivo (J. Wang et al., 2022).

La Precisión representa la proporción de defectos detectados correctamente respecto al número total de defectos. Se calcula tomando la relación entre el número de defectos predichos correctamente (TP) y el número total de muestras predichas (TP + FP) en los resultados de la detección. La fórmula de cálculo se expresa del siguiente modo (Feng et al., 2024).

$$Precision(P) = \frac{TP}{TP + FP}$$

El Recall representa la proporción entre el número de defectos detectados correctamente y el número de defectos reales. Se obtiene calculando la proporción entre el número de TP y el número de todos los defectos reales (TP + FN) en los resultados de la detección. La fórmula de cálculo se expresa de la siguiente manera (Feng et al., 2024).

$$Recall(R) = \frac{TP}{TP + FN}$$

La average precision (AP), es un indicador que evalúa el rendimiento de la red, mediante la interpolación de la curva PR en 11 puntos, la tasa de recuperación se divide en 10 intervalos equidistantes, y se hallan P y R en cada intervalo y se calcula la PA (Mahapatra et al., 2025).

$$AP = \int_0^1 P(R) dR$$

La media de la precisión media de cada categoría se utiliza como mAP, siendo N es el número de categorías. El valor mAP oscila entre 0 y 1. Cuanto más se acerque a 1, mayor será la capacidad de detección de la red y mejor su rendimiento (Han et al., 2019).

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

Además, la puntuación F1 se calcula utilizando la media armónica de recall y precisión. La media armónica sirve para sustituir a la media aritmética, que se utiliza con más frecuencia y puede expresarse de la siguiente manera (Lu et al., 2024).

$$F1 = 2x \frac{A_{Precision} \cdot x A_{Recall}}{A_{Precision} + A_{Recall}}$$

### III RESULTADOS

#### 3.1. Recolección de datos del procedimiento tradicional de inspección de aisladores en líneas de transmisión

Para llevar a cabo este análisis de resultados se empleó la información obtenida mediante una entrevista estructurada al supervisor y técnicos linieros de la empresa Consorcio Eléctrico Jaén (Ver anexo 5).

La inspección tradicional de los aisladores de la línea de transmisión SE Nueva Jaén – SE Jaén se efectuó mediante observación visual desde el nivel del suelo, sin ascenso a las estructuras ni contacto con los conductores energizados, siguiendo las normas de seguridad establecidas. La cuadrilla responsable estuvo conformada por dos técnicos linieros, dos ayudantes de apoyo y un conductor.

Previo al inicio de las labores, el personal participó de la charla de seguridad, revisó las herramientas para la ejecución del trabajo. En campo los técnicos efectuaron el registro fotográfico de cada estructura utilizando su dispositivo celular, capturando imágenes de las cadenas de aisladores. Dichas fotografías fueron posteriormente analizadas en gabinete por personal técnico liniero para determinar el estado de cada aislador.

**Tabla 11**

*Costos Operativos del Método Tradicional de Inspección*

<b>Concepto</b>	<b>Cantidad de Personal</b>	<b>Costo Unitario (S/.)</b>	<b>Costo Diario Total (S/.)</b>
<b>Técnico</b>	2	100.00	200.00
<b>Apoyo</b>	2	60.00	120.00
<b>Conductor</b>	1	53.33	53.33
<b>Combustible</b>	-	50.00	50.00
<b>Viáticos (Almuerzo)</b>	5	10.00	50.00
<b>Total, diario estimado</b>			<b>473.33</b>

*Nota.* Costos estimados según información obtenida en la entrevista a personal técnico y supervisor de la empresa colaboradora de Electro Oriente, Consorcio Eléctrico Jaén.

En la siguiente tabla 12 detalla el rendimiento promedio de la inspección tradicional de aisladores por estructura. El tiempo total considerando incluye tanto el traslado entre estructuras como la inspección visual y fotográfica desde el suelo.

**Tabla 12**

*Rendimiento por inspección de estructuras*

<b>Actividad Realizada</b>	<b>Tiempo Estimado (min)</b>	<b>Descripción de la actividad</b>
<b>Traslado hacia la estructura</b>	8	Desplazamiento del vehículo y posicionamiento del personal en la base de la torre.
<b>Inspección visual y toma fotográfica</b>	10	Revisión visual de la cadena de aisladores, estructura y toma de evidencia fotográficas.
<b>Registro y observaciones técnicas</b>	5	Anotación de hallazgos, observaciones y comunicación con el supervisor.
<b>Tiempo total por estructura</b>	<b>23 minutos</b>	

*Nota.* Los datos fueron obtenidos a partir de la información proporcionada de la entrevista.

La información presentada en la tabla 13 fue obtenida mediante una simulación de inspección en gabinete realizada por un técnico liniero con experiencia, quien evaluó y clasificó imágenes de aisladores según su estado físico. El registro del tiempo empleado en la clasificación manual de cada imagen permitió establecer una referencia del desempeño del método tradicional de inspección.

**Tabla 13**

*Registro de tiempo de evaluación de imágenes de aisladores en gabinete técnico*

<b>N° de fotografía</b>	<b>Tiempo empleado (segundos)</b>
1	66
2	78
3	72
4	60
5	90
6	66
7	84
8	78
9	60
10	66
<b>Tiempo promedio</b>	<b>72 segundos</b>

*Nota.* El tiempo varió según la calidad de imagen y el nivel de detalle para clasificar correctamente.

En estudios de inspección de aisladores basados en visión por computadora se ha demostrado que la comparación entre métodos tradicionales y enfoques automatizados basados en redes neuronales es un criterio relevante para analizar la eficiencia y aplicabilidad de los sistemas de inspección (Han et al., 2019). En ese sentido, los tiempos obtenidos se consideran válidos como línea base del método tradicional y serán utilizados para la comparación posterior con el sistema de inspección automatizada con Deep Learning.

### **3.2. Desarrollo del modelo Deep Learning para detección automática de fallas en aisladores**

Dado que la presente investigación está limitada al análisis superficial de los aisladores; se propuso tres estados para que la detección sea más adecuada y precisa.

**Tabla 14***Estados propuestos para la clasificación de aisladores*

<b>Estado del aislador</b>	<b>Descripción</b>	<b>Mantenimiento Requerido</b>
<b>Bueno</b>	Aislador en óptimas condiciones, sin suciedad ni roturas.	Ninguno
<b>Sucio</b>	Aislador con suciedad orgánica e inorgánica.	Preventivo/Correctivo
<b>Roto/Flameado</b>	Aisladores que presentan rupturas parciales, fisuras visibles o evidencia de hollín por flameo.	Correctivo

*Nota.* La clasificación se realizó considerando únicamente la superficie del aislador.

### **Base de datos**

La base de datos utilizada para el desarrollo del modelo Deep Learning fue construida a partir de imágenes capturadas mediante inspecciones aéreas con un dron Phantom 4 RTK y datasets públicos, de aisladores en diferentes estados: buenos, sucios y rotos o flameados. Inicialmente, la base de datos estuvo conformada por 2016 imágenes, distribuidas en 981 imágenes de aisladores en buen estado, 330 imágenes de aisladores sucios y 705 imágenes de aisladores rotos o flameados.

Posteriormente, durante la etapa de preprocesamiento, se aplicaron técnicas de optimización y aumento de datos, incluyendo variaciones en el ángulo de captura, condiciones iluminación y fondos complejos. Estas estrategias permitieron mejorar robustez del conjunto de datos el entrenamiento del modelo y mejorar su capacidad de generalización del modelo. Como resultado la base de datos final estuvo compuesta por un total de 2239 imágenes, distribuidas entre las distintas categorías: 1069 imágenes de

aisladores buenos, 660 imágenes de aisladores sucios y 510 correspondiente a aisladores rotos/flameados.

**Figura 20**

*Base de datos de las diferentes fallas en aisladores*



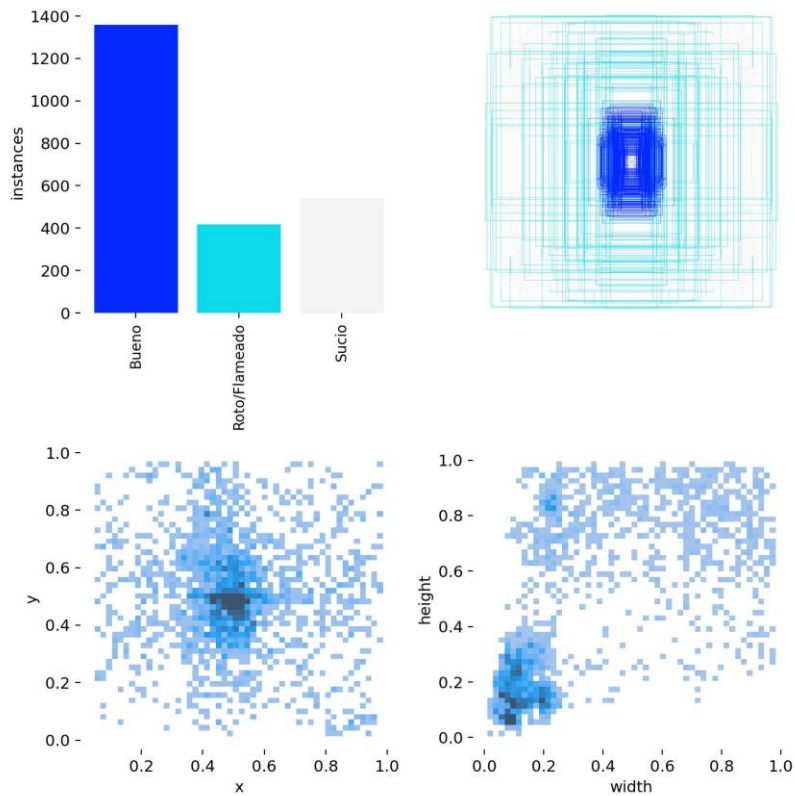
Fuente: Elaboración propia

La Figura 20 muestra un análisis estadístico detallado de la base de datos utilizada para el entrenamiento del modelo de detección, se muestra la distribución de frecuencias por clase, la superposición de las cajas delimitadoras indica que la mayoría de los aisladores se encuentran concentrados en la región central de las imágenes, facilitando su detección.

Los diagramas de dispersión confirman esta concentración espacial de los centros de cajas y muestran que las dimensiones relativas de las cajas delimitadoras mantienen proporciones consistentes y tamaños moderados en relación con el total de la imagen.

**Figura 21**

*Instancias de la base de datos*




Fuente: Elaboración propia

La figura 21 muestra la distribución de las instancias de la base de datos y el comportamiento espacial de las cajas delimitadoras normalizadas. Se observa que la clase “Bueno” concentra la mayor cantidad de muestras, mientras que (Roto/Flameado” presenta la menor proporción.

**Figura 22**

*Análisis correlacional de las variables*



Fuente: Elaboración propia

La Figura 22 muestra el análisis de correlación de las variables x, y, ancho y alto de las cajas delimitadoras normalizadas de la base de datos. En la diagonal principal se muestran los histogramas univariantes de cada parámetro, que permiten identificar su distribución individual. Se observó que las coordenadas x e y presentan distribuciones concentradas alrededor de 0.5, lo que confirma que la mayoría de los aisladores se encuentran en la región central de las imágenes.

Para mitigar el sobreajuste en los modelos de aprendizaje profundo, se amplió el conjunto de datos de forma eficaz, utilizando varias técnicas de aumento de datos, como rotaciones de ángulos, voltear imágenes vertical y horizontalmente y cambiar sus posiciones. Además, el modelo empleó técnicas de aumento como la técnica de mosaico y la técnica de mezcla. Realizando modificaciones del espacio de color, la saturación y exposición de la imagen para crear más datos de forma eficaz. Este aumento de datos ayudó a reducir la posibilidad de sobreajuste de la red y a mejorar la precisión de detección del modelo.


## **Modelo Deep Learning**

El modelo YOLO v11 tiene 168 capas y aproximadamente 3 millones de parámetros compuesta por bloques de convolución que incrementan progresivamente la dimensionalidad de los mapas de características desde 32 hasta 512 canales, lo que aseguró una extracción jerárquica eficiente de información visual. La integración de módulos C3k2 contribuye a la optimización del flujo de gradientes y a la mitigación del sobreajuste, mientras que el bloque SPPF (Spatial Pyramid Pooling – Fast) amplía el campo receptivo sin incrementar el costo computacional. Asimismo, el módulo C2PSA introduce mecanismos de atención espacial y de canal, lo cual refuerza la capacidad del modelo para discriminar patrones relevantes en la detección de defectos en aisladores.

En las etapas de fusión, las operaciones de upsampling y concat permitieron integrar características de distintas resoluciones, fortaleciendo la detección de objetos pequeños y con oclusiones parciales. Finalmente, la capa Detect, organizada en tres ramas de salida (128, 256 y 512), posibilitando un balance óptimo entre la detección global de aisladores y la identificación detallada de fallas en los aisladores. Tras una serie de operaciones, la entrada al modelo se presenta en la figura, donde 0 representa los aisladores "Bueno", 1: "Roto/Flameado" y 2: "Sucio" (ver figura 23).

**Figura 23**

*Mosaico de predicciones del modelo YOLOv11*



Fuente: Elaboración propia

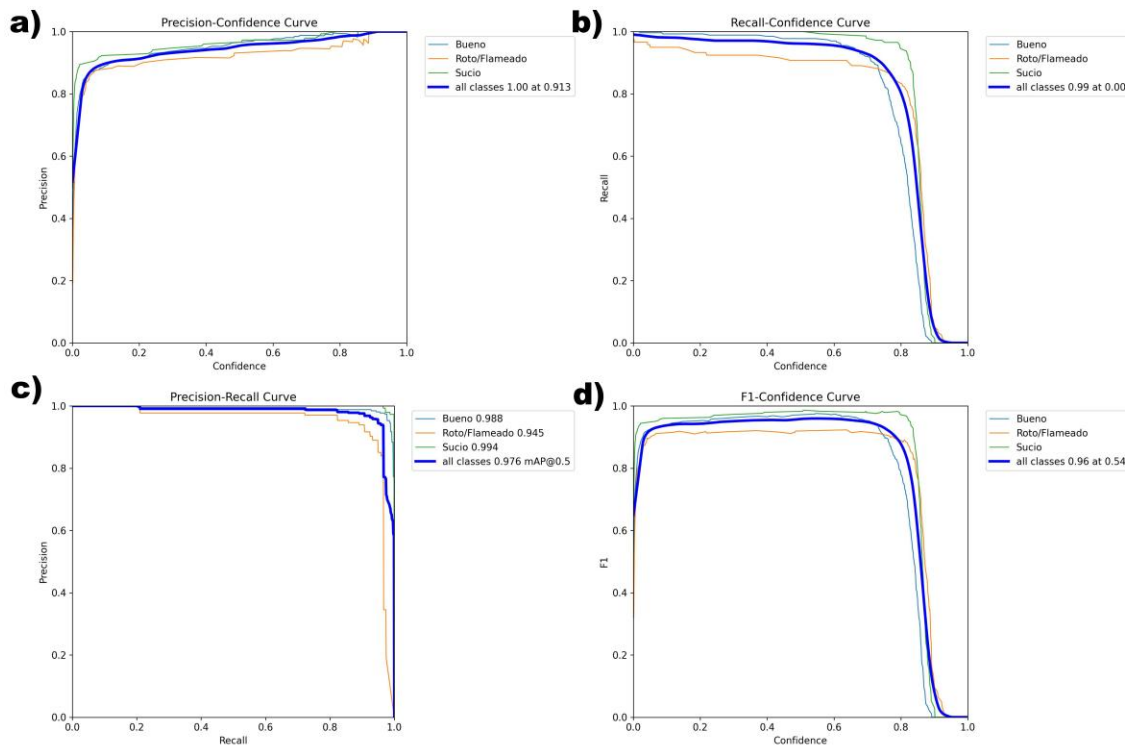
### **Entrenamiento y validación del modelo**

El entrenamiento de los modelos de Yolo v11 (yolos.pt y yolos.pt) arquitecturas de redes neuronales convolucionales (CNN) tuvo una duración de entre 1 y 2 horas por arquitectura. Se evaluó el desempeño del modelo a partir del dataset de testeo. Un parámetro clave durante el entrenamiento fue la tasa de aprendizaje, la cual se ajustó para optimizar el rendimiento de las redes. Además, se midió la velocidad de ejecución del algoritmo, utilizando la tasa de detección en fotogramas por segundo (FPS), que indica cuántas imágenes procesa el sistema por unidad de tiempo. Se probaron dos tasas de

aprendizaje aplicadas a todas las arquitecturas CNN planteadas para comparar su desempeño y eficiencia.

## Figura 24

### Gráficas del entrenamiento y validación



Fuente: Elaboración propia

En el gráfico Curva precisión-confianza (Figura 24-a), se observa que el modelo mantiene valores de precisión superiores al 90 % para niveles de confianza desde 0.2 hasta 0.91, con un valor máximo cercano al 100 % para las clases Sucio y Bueno. La clase Roto/Flameado muestra una ligera caída en la precisión a niveles de confianza bajos, lo que indicó una mayor probabilidad de falsos positivos en esta categoría.

El gráfico Recall-Confidence Curve (Figura 24-b), muestra que la exhaustividad se mantiene próxima a 1 en rangos bajos de confianza, disminuyendo de manera progresiva conforme aumenta el umbral. Este comportamiento evidencia que el modelo es capaz de detectar la mayoría de las instancias presentes en el conjunto de prueba, aunque un umbral de confianza excesivamente alto podría omitir algunas detecciones válidas.

En la Precision-Recall Curve (Figura 24-c), el área bajo la curva (AUC) es cercana a 1 para las tres clases, confirmando un balance óptimo entre precisión y recall. Destaca el desempeño sobresaliente de la clase Aisladores Sucio con un valor de 0.994, seguida de Aisladores Buenos con 0.988.

Finalmente, la F1-Confidence Curve (Figura 24-d) evidencia que el valor máximo de F1 se alcanza alrededor de un umbral de confianza de 0.55, con un desempeño global de 0.96.

### **Evaluación del modelo**

Las métricas de rendimiento de YOLOv11 en el conjunto de prueba se presentan en la Tabla 15, donde mAP50 representa el mAP calculado con un umbral de Intersección sobre Unión (IoU) de 0.50.

**Tabla 15**

*Métricas de evaluación del modelo YOLOv11 para el conjunto de validación*

Clases	Imágenes	Precisión	Recall	mAP50
Todo	430	0.956	0.963	0.977
Bueno	176	0.958	0.981	0.989
Roto/Flameado	113	0.937	0.908	0.951
Sucio	139	0.972	1.000	0.992

*Nota.* La tabla muestra el desempeño del modelo YOLOv11 en validación mediante los valores de precisión, Recall y mAP50 por clase.

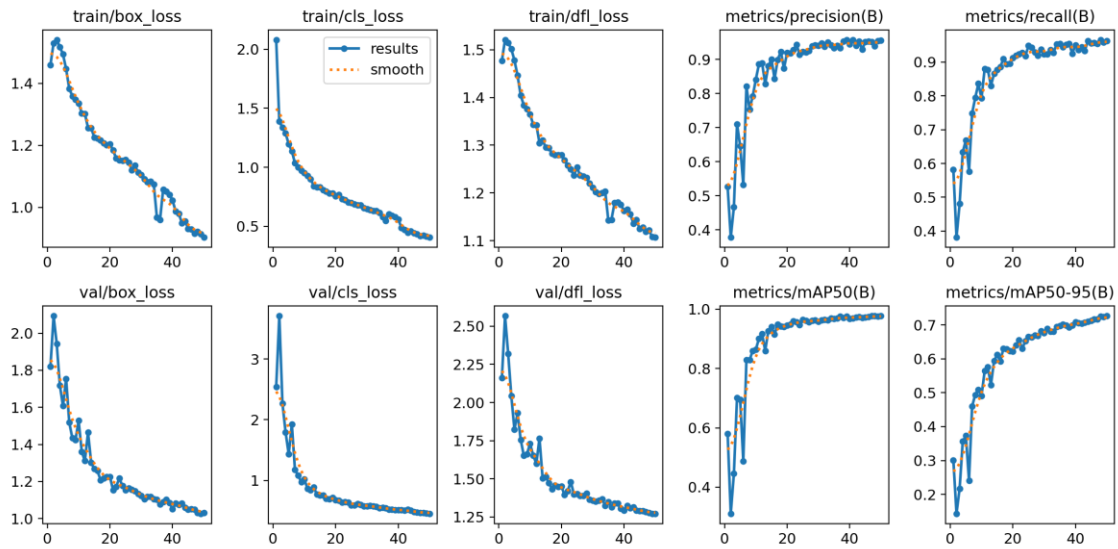
El rendimiento del modelo YOLOv11, del conjunto de prueba estuvo compuesto por 430 imágenes. Se muestran las métricas de precisión (Precisión), exhaustividad o sensibilidad (Recall) y mAP@0.5 (mean Average Precisión a IoU=0.5) para el conjunto completo y para cada clase de manera individual. De forma global, el modelo alcanzó una precisión de 0.956; lo que equivale a un 95.6%, un recall de 0.963; equivalente a un 96.3%, y un mAP@0.5 de 0.977 equivalente a 97.7%, lo que evidencia un desempeño sobresaliente y una capacidad robusta para identificar correctamente las instancias de aisladores en diferentes condiciones.

El Aislador Sucio obtuvo el mejor desempeño, con una precisión de 0.972, un recall de 1.000 y un mAP@0.5 de 0.992, lo que indica que el modelo es altamente confiable para identificar este tipo de falla. El Aislador Bueno también presentó métricas elevadas, con precisión de 0.958 y recall de 0.981, alcanzando un mAP@0.5 de 0.989, lo que confirma

la capacidad del modelo para discriminar correctamente las condiciones normales de los aisladores. Por su parte, la clase Aislador Roto/Flameado presentó un desempeño ligeramente inferior respecto a las demás categorías, con precisión de 0.937, recall de 0.908 y mAP@0.5 de 0.951.

### Figura 25

*Resultados del entrenamiento y validación del modelo Yolo v11(Yolon.pt)*



Fuente: Elaboración propia

La Figura 25, muestra las pérdidas asociadas al conjunto de entrenamiento: train/box\_loss, train/cls\_loss y train/dfl\_loss, las cuales exhiben un decrecimiento progresivo a medida que avanzan las épocas, lo que evidencia una convergencia estable del modelo. El box\_loss desciende desde valores iniciales de 1.5 hasta estabilizarse en torno a 0.8, indicando una mejora en la precisión de la regresión de las cajas delimitadoras. De forma análoga, la cls\_loss disminuye desde 2.0 hasta valores cercanos a 0.3, reflejando un aumento en la correcta clasificación de las instancias. La dfl\_loss sigue un patrón descendente continuo, corroborando el ajuste progresivo de las distribuciones de probabilidad para la predicción de las cajas.

**Figura 26**

*Resultados de detección de los aisladores roto/flameado*



Fuente: Elaboración propia

La Figura 26, muestra las detecciones realizadas por el modelo YOLOv11 en el conjunto de validación y evidencia su capacidad para identificar correctamente las diferentes clases de aisladores. En cada imagen se observan las cajas delimitadoras generadas por el modelo, junto con el nombre de la clase detectada y la probabilidad asociada a la predicción. Los resultados ponen de manifiesto que el modelo consigue una detección robusta y precisa en escenarios reales, incluso en condiciones de iluminación variables, fondos complejos y diferentes perspectivas de captura. Las clases Roto/Flameado y Sucio se identifican correctamente con valores de confianza superiores a 0.80 en la mayoría de los casos, lo que confirma la generalización del modelo.

**Tabla 16***Resultado matriz de confusión*

Estado	Predicción				Total
	Bueno	Roto/flameado	Sucio	Background	
Bueno	264	0	0	19	283
Roto/flameado	0	110	1	10	121
Sucio	0	3	143	6	152
Background	3	6	0	0	9
Total	267	119	144	35	565

*Nota.* La tabla muestra el rendimiento del modelo YOLOv11 al clasificar las clases Bueno, Sucio, Roto/Flameado

La tabla 16 muestra la matriz de confusión obtenida durante la validación del modelo YOLOv11, que evidencia el rendimiento de clasificación: Bueno, Roto/Flameado y Sucio. Se observa que la categoría Bueno presentó 264 verdaderos positivos de un total de 283 muestras, con 19 casos clasificados erróneamente como fondo. Este comportamiento indica que el modelo tiene una alta sensibilidad para identificar aisladores en buen estado.


La clase Roto/Flameado obtuvo 110 resultados positivos de 121, mostrando únicamente un error de clasificación hacia la categoría Sucio y diez hacia Background. Aunque el rendimiento es satisfactorio, este resultado confirma que los defectos estructurales más leves o parcialmente visibles pueden generar ambigüedad en el modelo y provocar una subdetección.

En la categoría Sucio, el modelo detectó correctamente 143 de las 152 instancias, clasificando solo 3 como Roto/Flameado y 6 como Background de forma errónea. Este comportamiento sugiere que la presencia de contaminación superficial es un patrón que el modelo ha aprendido bien, por lo que se convierte en una de las categorías con mayor precisión relativa.

Por último, el número de falsos positivos sobre el fondo fue bajo (9 en total), lo que implica que el modelo mantiene una buena capacidad de discriminación y evita clasificar objetos irrelevantes como aisladores (ver figura 27).

**Figura 27**

*Matriz de confusión*

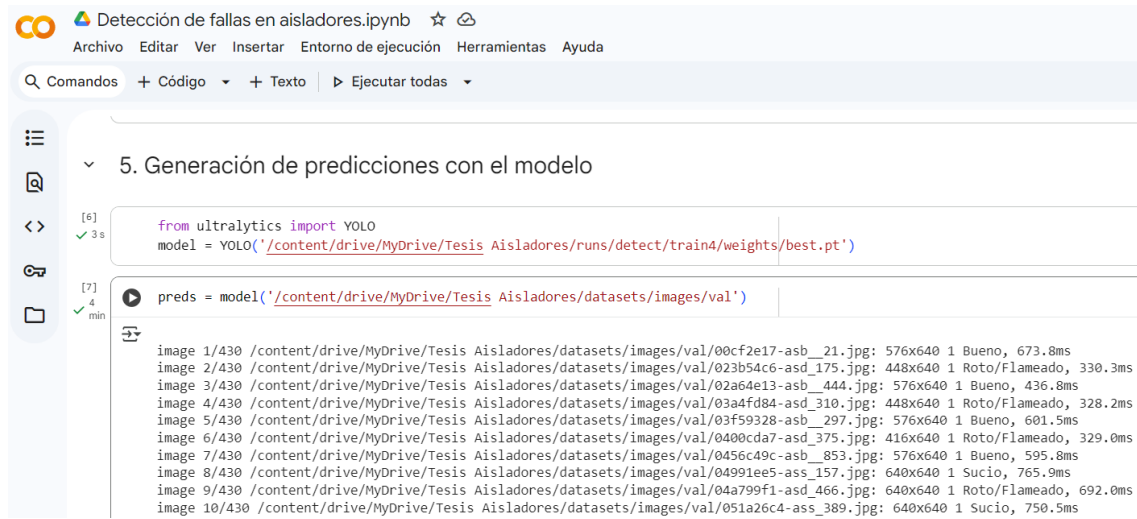


Fuente: Elaboración propia

Para la evaluación en gabinete con el modelo Deep Learning, se procesaron las mismas 10 imágenes utilizadas en la simulación realizadas por el técnico liniero. El modelo procesó las 10 imágenes en un tiempo de 5.5038 segundos con un promedio de 0.55038 segundos por imagen (ver tabla 17).

**Figura 28**

*Evaluación en gabinete con modelo Deep Learning*



The screenshot shows a Jupyter Notebook interface with the following content:

- Header: "Detección de fallas en aisladores.ipynb" with navigation options: Archivo, Editar, Ver, Insertar, Entorno de ejecución, Herramientas, Ayuda.
- Search bar: "Comandos" with filters for "Código", "Texto", and "Ejecutar todas".
- Section: "5. Generación de predicciones con el modelo".
- Code cell [6]:

```
from ultralytics import YOLO
model = YOLO('/content/drive/MyDrive/Tesis Aisladores/runs/detect/train4/weights/best.pt')
```
- Code cell [7]:

```
preds = model('/content/drive/MyDrive/Tesis Aisladores/datasets/images/val')
```
- Output: A list of 10 image predictions with their respective paths, dimensions, and classification results (e.g., "Bueno", "Roto/Flameado", "Sucio") along with processing times in milliseconds.

Fuente: Elaboración propia

**Tabla 17**

*Registro de tiempos de evaluación de imágenes en gabinete con Deep Learning*

Nº de fotografía	Tiempo empleado (milisegundos)
1	673.8
2	330.3
3	436.8
4	328.2
5	601.5
6	329.0
7	595.8
8	765.9
9	692.0
10	750.5
<b>Tiempo promedio en segundos</b>	<b>0.55038</b>

*Nota.* El tiempo varió según la calidad de imagen y el nivel de detalle para clasificar correctamente.

### **3.3. Comparación de la productividad en detección de fallas de aisladores con el modelo Deep Learning y el método tradicional**

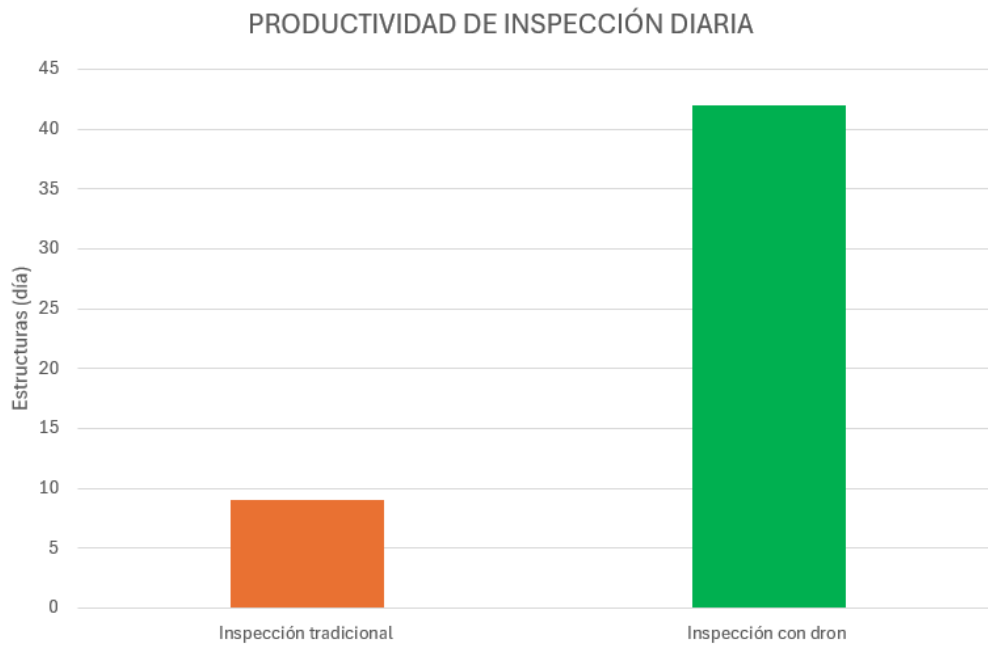
La comparación de la productividad entre el método tradicional de inspección y el método propuesto con Deep Learning y dron se realizó considerando los indicadores de tiempo operativo, costos diarios, número de estructuras inspeccionadas por jornada y precisión de detección de fallas. Asimismo, se evaluaron los niveles de riesgo operativo y la cantidad de personal requerido, con el fin de determinar la eficiencia de ambos procedimientos.

En el método tradicional, de acuerdo a la información obtenida en la entrevista, presentó un tiempo promedio de 23 minutos por estructura, lo que permitió cubrir entre 8 y 10 estructuras diarias para la inspección de estructuras. Este procedimiento demandó una cuadrilla conformada por 5 integrantes (2 técnicos, 2 ayudantes y 1 conductor), generando un costo diario de S/. 473.33 (Ver tablas 11 y 12). Además, el análisis manual de las fotografías recolectadas implicó un promedio de 72 segundos por imagen, lo que extendió el tiempo de diagnóstico y aumentó la posibilidad de errores por fatiga visual o subjetividad del observador.

Por otro lado, el método propuesto con el dron Phantom 4 RTK y modelo de Deep Learning YOLOv11 evidenció un desempeño sustancialmente superior. El tiempo total para la inspección de las 17 estructuras fue de 168.3 minutos, lo que equivale a (2 horas y 48 minutos), con un promedio de 9.9 minutos por estructura, (ver tabla 5). Considerando una jornada laboral efectiva de 7 horas (420 minutos), descontando una hora destinada al almuerzo, se estima que es posible inspeccionar aproximadamente 42 estructuras diarias, utilizando el dron y un costo de S/. 383.33, correspondiente al trabajo de un técnico liniero, un conductor y un operador del dron.

**Figura 29**

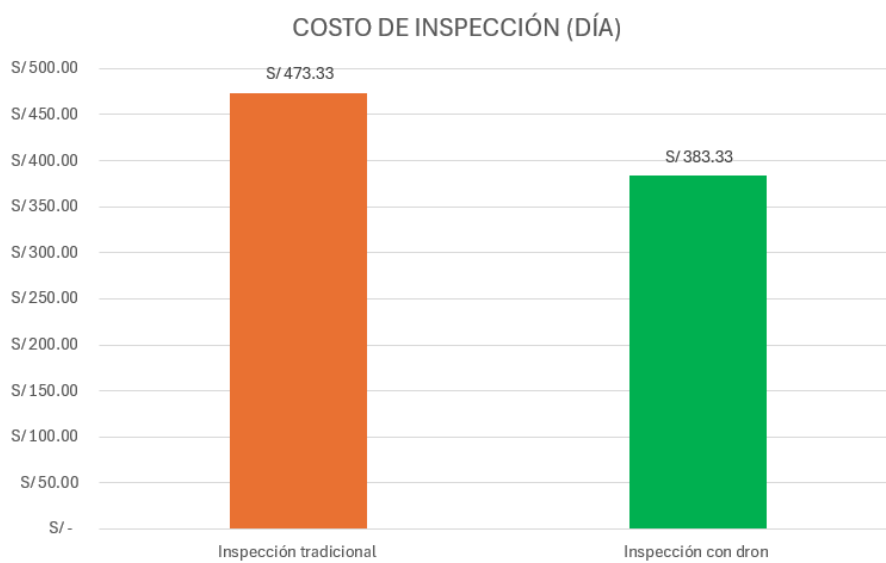
*Productividad de inspecciones diarias con ambos métodos*



*Nota.* Con el método tradicional se inspeccionó de 8 a 10 estructuras, mientras que con el método Deep Learning y dron se estima inspeccionar un promedio de 42 estructuras diarias.

**Figura 30**

*Costo de inspección diaria con ambos métodos*




*Nota.* Comparación de costos de inspección diaria con el método tradicional y el método Deep Learning, obteniendo una reducción del 19.01% en costos operativos.

En la figura 31 muestra la cantidad personal requerido para ambos métodos. El método tradicional requiere de 5 personas equivalente a un 62.5% mientras que el método con Deep Learning requiere de 3 personas correspondiente a un 37.5%, mostrando una reducción del 40% en el personal requerido.

### Figura 31

*Personal requerido para la inspección de aisladores*



Fuente: Elaboración propia

La figura 32 presenta la comparación del tiempo promedio de procesamiento por imagen entre el método tradicional realizado por el técnico liniero y el modelo Deep Learning durante la evaluación en gabinete. Se observa que el técnico liniero requirió en promedio 72 segundos por imagen, mientras que el modelo Deep Learning procesó cada imagen en un promedio de 0.55038 segundos, evidenciando una reducción significativa en el tiempo de análisis.

**Figura 32**

*Tiempo de procesamiento de imágenes en gabinete*



Fuente: Elaboración propia

**Tabla 18**

*Productividad entre el método tradicional y el método Deep Learning y dron*

Indicador	Método tradicional	Deep Learning y dron	Variación/Mejora
Tiempo promedio por estructura	23 min	9.9 min	- 57%
Estructuras inspeccionadas por día	8 a 10	42	+ 367%
Tiempo de procesamiento por imagen en gabinete	72 seg	0.55 seg	- 99.24%
Personal requerido	5	3	- 40%
Costo diario estimado	S/. 473.33	S/.383.33	- 19%
Precisión de detección	Subjetiva (visual)	95.6% (YOLOv11)	+ Alta confiabilidad
Riesgo operativo	Alto (exposición eléctrica)	Bajo (operación remota)	- 100%

**Nota.** Elaboración propia (2025). Comparación de los resultados obtenidos.

## IV DISCUSIÓN

En relación con el primer objetivo específico, enfocado en la recolección de datos del procedimiento tradicional de inspección y detección de fallas en aisladores, los resultados evidencian importantes limitaciones operativas. El procedimiento tradicional permite inspeccionar entre 8 y 10 estructuras por día, con un tiempo promedio de 23 minutos por estructura, empleando una cuadrilla de cinco personas y un costo diario estimado de S/ 473.33. Asimismo, el análisis en gabinete para la clasificación de imágenes requiere un promedio de 72 segundos; por imagen, lo que incrementa el tiempo total del proceso y expone el diagnóstico de errores asociados a la fatiga visual y la subjetividad del evaluador. Estos resultados son coherentes con los estudios reportados por Han et al. (2019) y Huallpa (2020), quienes señalan que los métodos tradicionales presentan bajos niveles de eficiencia, elevados tiempos operativos y altos costos en la inspección de las líneas eléctricas.

De acuerdo con el segundo objetivo, referido al desarrollo de un modelo de un modelo de Deep Learning para detección automática de fallas en aisladores utilizando imágenes capturadas mediante dron, los resultados demuestran que el modelo YOLOv11 desarrollado presenta un desempeño sobresaliente. El modelo alcanzó una precisión del 95.6%, un Recall de 96.3% y un mAP@0.5 de 97.7%, así como un tiempo promedio de procesamiento por imagen de 0.55 segundos evidenciando una alta capacidad para identificar correctamente aisladores en buen estado, sucios y rotos/flameados. Estos resultados superan los reportados por Astudillo y Catota (2025), quienes emplearon la arquitectura YOLOv5 y alcanzaron una precisión del 93% y un Recall 90%, además de un tiempo promedio de procesamiento por imagen de 1 segundo fuera de línea, y comparables con los resultados obtenidos por Liu et al. (2021), quienes reportaron una precisión del 98% y un Recall del 95% utilizando YOLOv3 mejorado. Por otro lado, Lei y Sui (2019), emplearon métodos más complejos como Faster R-CNN con ResNet-101 reportando una precisión promedio de 97.6% y un Recall promedio de 97.9%. De la comparación realizada se deduce que el modelo YOLOv11 ofrece un equilibrio eficiente entre precisión y velocidad de procesamiento, superando arquitecturas anteriores y resultando más adecuado que los modelos más complejos para aplicaciones de inspección en tiempo real mediante dron.

Finalmente, con relación al tercer objetivo, orientado a comparar la productividad en la detección de fallas de aisladores, entre el método tradicional y el enfoque propuesto, los resultados evidencian mejoras sustanciales al integrar el uso de drones y Deep Learning. El tiempo promedio por estructura se redujo de 23 a 9.9 minutos, lo que representa una mejora del 57% en la eficiencia del proceso; la cantidad del personal técnico requerido disminuyó de cinco a tres personas, equivalente a una reducción del 40%; y la cantidad de estructuras inspeccionadas por día se incrementó de 8 – 9 a 42, alcanzando un aumento del 367% en productividad y reducir los costos operativos en un 19%. Estos resultados concuerdan con los reportados por Silva (2023), quien evidenció una reducción del tiempo de inspección de 20 – 30 a 8 – 10 minutos, lo que equivale a una mejora del 69% de eficiencia; una disminución del personal técnico de cuatro a dos lo que representó una reducción del 50%; así como también aumentó su productividad en un 220%, y por Huallpa (2020), quien reportó una reducción del 55.9% en el tiempo total de inspección, un incremento del 54.5% en productividad por estructura y una reducción del 63.99% en los costos operativos respecto al método tradicional. En coherencia con estos estudios, los resultados de la presente investigación confirman que la aplicación de dron y Deep Learning en la inspección de líneas de transmisión mejora la eficiencia operativa, reduce los costos y aumenta la productividad en el mantenimiento de sistemas eléctricos.

Una de las principales limitaciones encontradas en el desarrollo del proyecto fue la escasez de imágenes locales de aisladores defectuosos, lo que obligó a complementar la base de datos con fuentes externas. Si bien esto permitió entrenar el modelo con una mayor variedad de ejemplos, también introduce el desafío de garantizar la representatividad de las condiciones locales. Este aspecto sugiere la necesidad de investigaciones complementarias orientadas a construir bases de datos nacionales que reflejen los distintos tipos de aisladores y las condiciones ambientales del sistema eléctrico peruano.

## V CONCLUSIONES Y RECOMENDACIONES

### 5.1. Conclusiones

1. Se concluye que la aplicación de Deep Learning y dron permitió aumentar la productividad en la detección de fallas en aisladores de una línea de transmisión en Jaén – Cajamarca, al optimizar los tiempos de inspección, reducir los recursos humanos y disminuir los costos operativos, demostrando la viabilidad técnica y operativa del enfoque propuesto frente al método tradicional.
2. El análisis del método tradicional de inspección permitió identificar importantes limitaciones operativas, al permitir inspeccionar solo entre 8 y 10 estructuras por día, con un tiempo promedio de 23 minutos por estructura, una cuadrilla de cinco personas y un tiempo de clasificación en gabinete de 72 segundos (1.2 minutos); por imagen, lo que genera baja de eficiencia, mayores costos y alta dependencia del factor humano.
3. En relación con el desempeño del modelo propuesto, el sistema Deep Learning basado en la arquitectura YOLOv11 desarrollado en esta investigación, presentó un desempeño sobresaliente en la detección automática de fallas en aisladores, alcanzando una precisión del 95.6%, un Recall del 96.3%, un mAP@0.5 de 97.7% y un tiempo de procesamiento de 0.55 segundos (aproximadamente 0.01 minutos) por imagen, superando arquitecturas previas y resultando adecuado para aplicaciones de inspección en tiempo real mediante drones.
4. Finalmente, la implementación del enfoque propuesto permitió reducir el tiempo de inspección por estructura de 23 a 9.9 minutos (57%), disminuir el personal requerido de cinco a tres personas (40%), aumentar la inspección diaria de 8-10 a 42 estructuras diarias (367%) y reducir los costos operativos en un 19%, evidenciando una mayor eficiencia frente al método tradicional.

## 5.2. Recomendaciones

1. Se recomienda mantener una distancia de seguridad adecuada respecto a las líneas de transmisión durante la captura de imágenes, a fin de prevenir riesgos asociados a los campos electromagnéticos y garantizar la estabilidad operativa del dron. Asimismo, es fundamental considerar las condiciones de iluminación en campo, ya que variaciones excesivas de luz pueden afectar la calidad de las imágenes y reducir la precisión del algoritmo de detección automática.
2. Adoptar de manera progresiva el uso de drones y sistemas Deep Learning en las inspecciones de aisladores, priorizando las líneas de transmisión críticas, para aprovechar los beneficios en productividad y reducción de costos.
3. Se recomienda implementar un sistema integral de inspección en tiempo real que combine el vuelo autónomo de drones con la detección automática mediante el modelo Deep Learning, permitiendo diagnósticos inmediatos ante fallas en aisladores, lo que facilitará la toma de decisiones más eficiente para el mantenimiento preventivo y correctivo.
4. Se recomienda reentrenar el modelo propuesto con nuevas imágenes locales, con el fin de mantener una alta precisión en las inspecciones.

## VI REFERENCIAS BIBLIOGRÁFICAS

- AI- Top Topografía. SA. (2019). *Dji Phantom 4RTK*. <https://al-top.com/wp-content/uploads/2019/01/DJI-Phantom-4-RTK.pdf>
- Astudillo Cortez, V. P. (2022) *Identificación de fallas en aisladores de una línea de transmisión mediante visión artificial* [Tesis para optar el grado de Magister en Electricidad, Universidad Técnica de Cotopaxi]. <http://repositorio.utc.edu.ec/handle/27000/8801>
- Astudillo, V. P., & Catota, P. (2025). Application of Artificial Vision Based on Convolutional Neural Networks for Predictive Detection of Faults in Electrical Distribution Line Insulators. *International Journal of Electrical and Computer Engineering Systems*, 16(3), 243-251. <https://doi.org/10.32985/ijeces.16.3.5>
- Beleño Díaz, B., Mondragón Bernal, C., & Parra Rodríguez. (2020). Inspección De Aisladores En Líneas De Transmisión Eléctrica Usando Inteligencia Artificial. <https://doi.org/10.24054/rcta.v2i36.25>
- Campbell S, Greenwood M, Prior S, et al. Muestreo intencional: ¿complejo o simple? Ejemplos de casos de investigación. *Revista de Investigación en Enfermería*. 2020;25(8):652-661. Doi: [10.1177/1744987120927206](https://doi.org/10.1177/1744987120927206)
- Canchaya Huaytalla, B. A. (2021) *El vant o dron como tecnología de supervisión remota en la protección contra sobretensiones de frente rápido en las líneas de transmisión de la región Junín* [Tesis de pregrado, Universidad Nacional del centro del Perú]. <http://repositorio.uncp.edu.pe/handle/20.500.12894/8144>
- Deng, F., Xie, Z., Mao, W., Li, B., Shan, Y., Wei, B., & Zeng, H. (2022). Research on edge intelligent recognition method oriented to transmission line insulator fault detection. *International Journal of Electrical Power & Energy Systems*, 139, 108054. <https://doi.org/10.1016/j.ijepes.2022.108054>

- Diaz Bravo, L., Torruco García, U., Martínez Hernández, M. y Valera Ruiz, M. (2013). La entrevista, recurso flexible y dinámico. *Investigación en educación Médica*, 2(7), 162-167. Recuperado en 13 de agosto de 2025, de [http://www.scielo.org.mx/scielo.php?script=sci\\_arttext&pid=S2007-50572013000300009&lng=es&tlng=es](http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S2007-50572013000300009&lng=es&tlng=es)
- DJI Agriculture. (2025). *Phantom 4 RTK- Specs*. <https://ag.dji.com/phantom-4-rtk/specs>
- Docs Ultralytics. (2025). *Ultralytics YOLO11*. <https://docs.ultralytics.com/es/models/yolo11/>
- Electric Power Research Institute. (2016). *Transmission line inspection reference book: 345 kv and above (3rd ed.)*. EPRI.
- Fahim, F. y Hasan, Md. S. (2024). Enhancing the reliability of power grids: A YOLO based approach for insulator defect detection. *e-Prime - Advances in Electrical Engineering, Electronics and Energy*, 9(2024), 100663. <https://doi.org/10.1016/j.prime.2024.100663>
- Faisal, M. A. A., Mecheter, I., Qiblawey, Y., Hernandez Fernandez, J., Chowdhury, M. E. H., & Kiranyaz, S. (2025). *Deep learning in automated power line inspection: A review*. *Applied Energy*, 385, 12557. <https://doi.org/10.1016/j.apenergy.2025.125507>
- Feng, F., Yang, X., Yang, R., Yu, H., Liao, F., Shi, Q., & Zhu, F. (2024). An Insulator Defect Detection Network Combining Bidirectional Feature Pyramid Network And Attention Mechanism in Unmanned Aerial Vehicle Images. SSRN. <https://doi.org/10.2139/ssrn.4928072>
- Fontalvo-Herrera, T., De La Hoz-Granadillo, E., & Morelos-Gómez, J. (2017). La productividad y sus factores: Incidencia en el mejoramiento organizacional. *Dimensión Empresarial*, 15(2), 47–60. <https://doi.org/10.15665/rde.v15i2.1375>
- GEDISA. (2013). *Líneas de transmisión y distribución de energía eléctrica (Cap. 1)*. GEDISA Ingeniería. [https://www.gedisa.com.ve/recientes\\_aun/catalogos/electricos/libreria\\_herrajes/libreria/02%20CAP%201%20GEDIline%202013.pdf](https://www.gedisa.com.ve/recientes_aun/catalogos/electricos/libreria_herrajes/libreria/02%20CAP%201%20GEDIline%202013.pdf)

- Han, J., Yang, Z., Zhang, Q., Chen, C., Li, H., Lai, S., Hu, G., Xu, C., Xu, H., Wang, D., & Chen, R. (2019). A Method of Insulator Faults Detection in Aerial Images for High-Voltage Transmission Lines Inspection. *Applied Sciences*, 9(10), 2009. <https://doi.org/10.3390/app9102009>
- Hernández, R., Fernández, C. y Baptista, P. (2014). *Metodología de la investigación*. McGraw Hill. <https://dialnet.unirioja.es/servlet/libro?codigo=775008>
- Huallpa Palomino, R. (2020) *Aplicación del sistema de aeronave pilotada a distancia para optimizar la supervisión del alimentador eléctrico de ingenio – Electrocentro S.A.* [Tesis de pregrado, Universidad Nacional del centro del Perú]. <http://repositorio.uncp.edu.pe/handle/20.500.12894/6345>
- Jicheng, T. (2021). Detección automática de aisladores en líneas eléctricas mediante imágenes aéreas impulsadas por redes neuronales convolucionales. *IOPscience*, 1748(4), 1742-6596. <https://doi.org/10.1088/1742-6596/1748/4/042012>
- Khanam, R., & Hussain, M. (2024). YOLOv11: An Overview of the Key Architectural Enhancements (No. arXiv:2410.17725; Versión 1). arXiv. <https://doi.org/10.48550/arXiv.2410.17725>
- LeCun, Y., Bengio, Y y Hinton, G. (2015). Aprendizaje profundo. *Nature*, 521(1), 436-444. <https://doi.org/10.1038/nature14539>
- Lei, X., & Sui, Z. (2019). Intelligent fault detection of high voltage line based on the Faster R-CNN. *Measurement*, 138, 379-385. <https://doi.org/10.1016/j.measurement.2019.01.072>
- Liu, J., Liu, C., Wu, Y., Xu, H., & Sun, Z. (2021). An Improved Method Based on Deep Learning for Insulator Fault Detection in Diverse Aerial Images. *Energies*, 14(14), 4365. <https://doi.org/10.3390/en14144365>
- Liu, Y., Liu, D., Huang, X., & Li, C. (2023). Insulator defect detection with deep learning: A survey. *IET Generation, Transmission & Distribution*, 17(16), 3541-3558. <https://doi.org/10.1049/gtd2.12916>

- Lozada, J. (2014). Investigación Aplicada: Definición, Propiedad Intelectual e Industria. *CienciAmérica*, 3(1), 47-50  
<https://dialnet.unirioja.es/servlet/articulo?codigo=6163749>
- Lu, Q., Lin, K., & Yin, L. (2024). 3D attention-focused pure convolutional target detection algorithm for insulator defect detection. *Expert Systems with Applications*, 249, 123720. <https://doi.org/10.1016/j.eswa.2024.123720>
- Mahapatra, U., Rahman, M. A., Islam, Md. R., Hossain, Md. A., Sheikh, Md. R. I., & Hossain, M. J. (2025). Adversarial training-based robust model for transmission line's insulator defect classification against cyber-attacks. *Electric Power Systems Research*, 245, 111585. <https://doi.org/10.1016/j.epsr.2025.111585>
- Oberweger, M., Wendel, A., & Bischof, H. (2014). Visual Recognition and Fault Detection for Power Line Insulators.
- Opazo Barboza, J.D. (2020) *Detección e inspección de torres de alta tensión mediante procesamiento de imágenes aéreas y aprendizaje profundo* [Tesis para optar el título de Bachiller en Ciencias con mención en Ingeniería Electrónica, Pontificie Universidad Católica del Perú]. <http://hdl.handle.net/20.500.12404/15976>
- Pita Fernández, S y Pértigas Díaz, S. (2002). Investigación cuantitativa y cualitativa. *Cadaten primaria*, 9(1),76-78.  
[http://www.ecominga.uqam.ca/ECOMINGA\\_2011/PDF/BIBLIOGRAPHIE/GUIDE\\_LECTURE\\_2/4/2.Pita\\_Fernandez\\_y\\_Pertegas\\_Diaz.pdf](http://www.ecominga.uqam.ca/ECOMINGA_2011/PDF/BIBLIOGRAPHIE/GUIDE_LECTURE_2/4/2.Pita_Fernandez_y_Pertegas_Diaz.pdf)
- Potnuru, S. P. (2016). Review on Machine Vision based Insulator Inspection Systems for Power Distribution System. *Journal of Engineering Science and Technology Review*, 9, 135-141. <https://doi.org/10.25103/jestr.095.21>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). *You Only Look Once: Unified, real-time object detection*.  
<https://doi.org/10.48550/arXiv.1506.02640>

- Sarduy Domínguez, Y. (2007). Análisis de información y las investigaciones cuantitativa y cualitativa. *Revista Cubana Salud Publica*. 33(3) Recuperado en 01 de agosto de 2024, de [http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S0864-34662007000300020&lng=es&tlng=es](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S0864-34662007000300020&lng=es&tlng=es)
- Silva Esquen, R. A. (2023). *Utilización de Dron para mejorar el proceso de registro de mediciones eléctricas en redes de baja tensión* [Tesis de pregrado, Universidad Cesar vallejo]. <https://repositorio.ucv.edu.pe/handle/20.500.12692/116714>
- Stefenon, S. F., Seman, L. O., Singh, G., & Yow, K.-C. (2025). Enhanced insulator fault detection using optimized ensemble of deep learning models based on weighted boxes fusion. *International Journal of Electrical Power & Energy Systems*, 168, 110682. <https://doi.org/10.1016/j.ijepes.2025.110682>
- Tkachenko, M., Malyuk, M., Holmanyuk, A., & Liubimov, N. (2020–2025). Label Studio: Data labeling software [Software de código abierto]. HumanSignal. <https://github.com/HumanSignal/label-studio>
- Ultralytics YOLO. (2025). *Modelo practico de YOLOv8 basado en un conjunto de datos personalizado*. <https://www.51cto.com/aigc/2600.html#ultralytics-yolo-format>
- Wang, J., Li, Y., & Chen, W. (2022). Detection of Glass Insulators Using Deep Neural Networks Based on Optical Imaging. *Remote Sensing*, 14(20), 5153. <https://doi.org/10.3390/rs14205153>
- Wang, Q., Li, Y., Cui, S., Li, N., Zhang, X., Jiang, W., Peng, W., & Sun, J. (2024). Enhanced recognition of insulator defects on power transmission lines via proposal-based detection model with integrated improvement methods. *Engineering Applications of Artificial Intelligence*, 136, 109078. <https://doi.org/10.1016/j.engappai.2024.109078>

## **AGRADECIMIENTO**

A Dios, por otorgarnos cada nuevo día y la fortaleza necesaria para cumplir nuestros objetivos; a nuestros padres, por su dedicación constante, su amor infinito y su inspirador ejemplo de esfuerzo; y a nuestros docentes, en especial al Dr. Ing. Ricardo Ángel Shimabuku Ysa, por el saber transmitido, la orientación brindada y el apoyo recibido durante nuestro desarrollo profesional.

## **DEDICATORIA**

A mis padres, por ser mi mayor inspiración y ejemplo de esfuerzo. Por su amor incondicional, sacrificio y apoyo constante en cada paso de mi vida. Este logro es tan mío como suyo, pues sin ustedes nada de esto habría sido posible.

**Salomón Cubas Quevedo**

A mis padres, Liyder y Graciela, pilares de mi vida. Cada página de este trabajo lleva impregnado el sacrificio de sus manos, sus consejos y el amor incondicional que siempre me ha sostenido. Gracias por cada desvelo, por cada palabra de aliento y por creer en mi en todo momento.

A mis hermanos, Ángel y Fernanda, mis compañeros de vida. Gracias por ser mi refugio, por su apoyo constante y por recordarme siempre el valor de la familia.

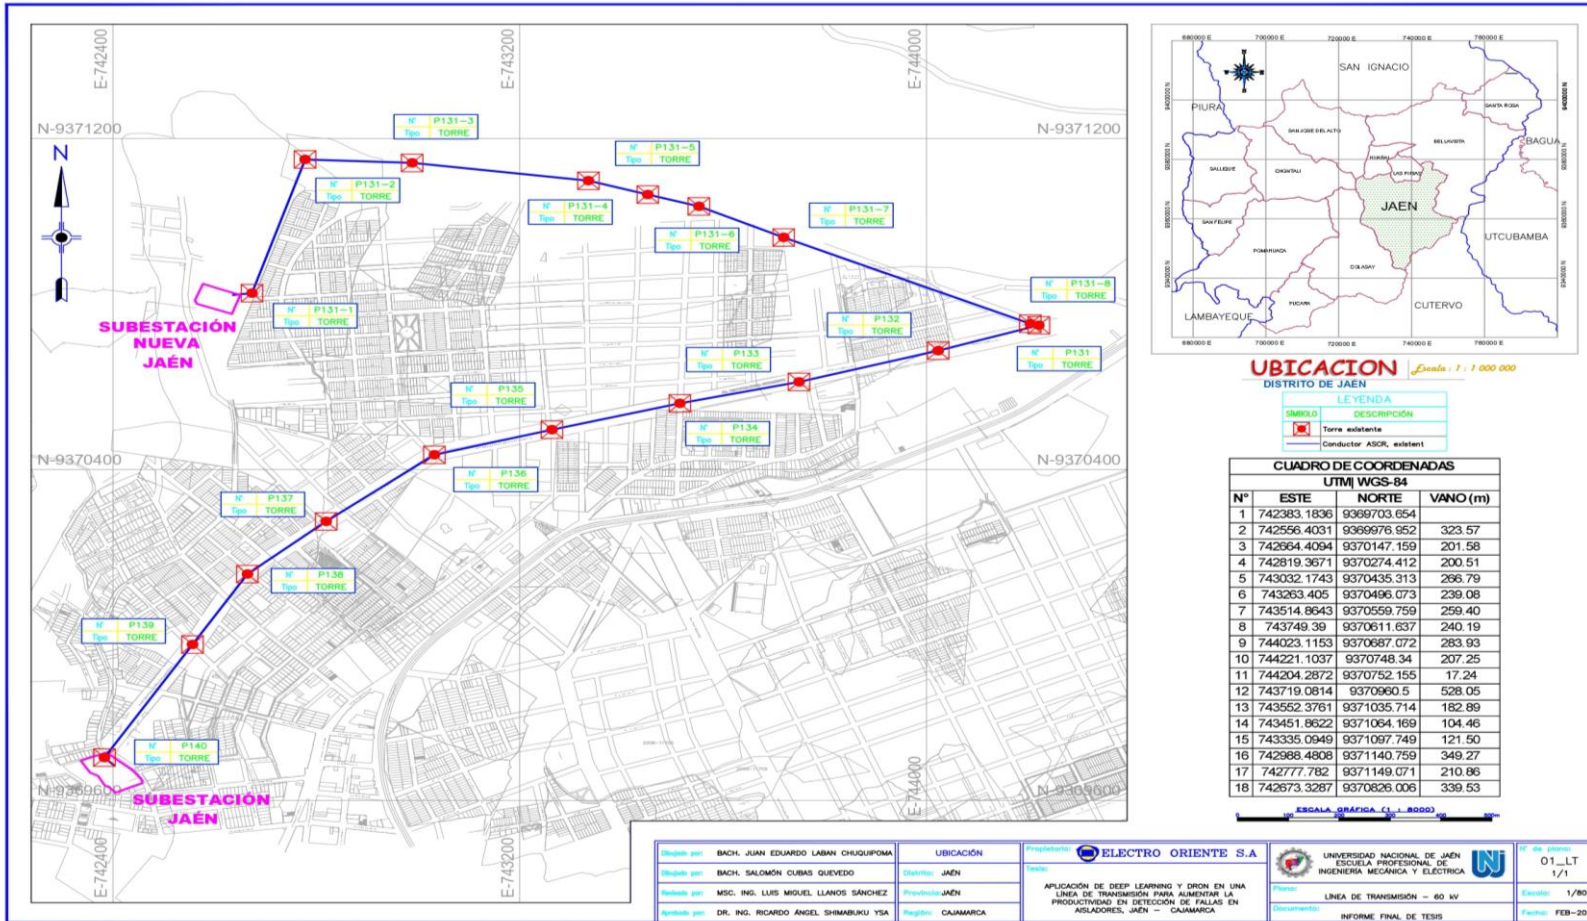
Este logro también les pertenece, porque su amor y su apoyo han sido la base que me permitió llegar hasta aquí.

**Juan E. Laban Chuquipoma**

# ANEXOS

## Anexo 1

### Objeto de Estudio



## Anexo 2

### Población y muestra

LÍNEA	CARACTERÍSTICAS								CONDUCTOR			CARACTERÍSTICAS DE LAS ESTRUCTURAS				CANTIDAD AISLADORES		CABLE DE GUARDA						
	REGIÓN	TENSIÓN NOMINAL (KV)	NOMBRE	NUM. DE TERNAS	LONGITUD (KM)	CANT. DE ESTRUCTURAS	CAPACIDAD DE TRANSPORTE	AÑO DE PUESTA EN SERVICIO	MATERIAL	SECCIÓN (mm <sup>2</sup> )	DIÁMETRO DEL CABLE (mm)	N° DE HILOS	PESO (kg/m)	MATERIAL 2	TIPO	DISPOSICIÓN DE CONDUCTORES	CANTIDAD DE TORRES	DESCRIPCIÓN	SUSPENSIÓN	ANCLAJE	TIPO 2	CUBIERTA DE LOS ALAMBRES DE ACERO	TIPO 3	SECCIÓN (mm <sup>2</sup> ) 4
L-60751-J(*)	SELVA	60	KV	UNA	4.17	17	12	1995	ACSR	78.6	11.35	6	0.273	ACERO	NIZAD	R	17	línea de	18	6	POLIMÉRICO/VIDRIO	GALVANIZADO	EHS	51.08

*Nota.* Este cuadro muestra la cantidad de estructuras en la línea SE Nueva Jaén- SE Jaén. Fuente: Electro Oriente.

### Anexo 3

Instrumento de recolección de datos



**UNIVERSIDAD NACIONAL DE JAÉN**  
**CARRERA PROFESIONAL DE INGENIERÍA MECÁNICA Y ELÉCTRICA**



**PROYECTO DE TESIS:** APLICACIÓN DE DEEP LEARNING Y DRON EN UNA LÍNEA DE TRANSMISIÓN PARA AUMENTAR LA PRODUCTIVIDAD EN DETECCIÓN DE FALLAS EN AISLADORES, JAÉN-CAJAMARCA.

**ENTREVISTA ESTRUCTURADA**

<b>REGIÓN:</b> Cajamarca	<b>PROVINCIA:</b> Jaén	<b>LUGAR:</b> Jaén	<b>FECHA:</b>
<b>ENTREVISTADOR:</b>			<b>DNI:</b>
<b>ENTREVISTADO 1:</b>			<b>DNI:</b>
<b>ENTREVISTADO 2:</b>			<b>DNI:</b>
<b>ESPECIALIDAD 1:</b>			
<b>ESPECIALIDAD 2:</b>			

\*\*Las preguntas del 1 al 6 se dirigen específicamente al equipo técnico y al responsable del área de mantenimiento, mientras que las preguntas 7 y 8 están destinadas exclusivamente al responsable del área de mantenimiento.

1. ¿Cómo se realizan las inspecciones de mantenimiento preventivo para detectar las fallas en aisladores en las líneas de transmisión en la actualidad?
2. ¿De cuántos técnicos requiere para una inspección y detección de fallas en aisladores por estructura?
3. ¿Cuánto tiempo dura realizar este trabajo de inspección?
4. ¿Cuál es la cantidad de inspecciones que pueden realizar en una jornada de trabajo de 8 horas?
5. ¿Cuáles son los posibles riesgos a los que se enfrenta el personal técnico durante las actividades de inspección?
6. ¿Considera que la productividad podría aumentar mediante la aplicación del Deep Learning y dron?
7. ¿Cuáles son los costos asociados a la inspección tradicional por jornada de trabajo?
8. ¿Considera que los costos de inspección se verían disminuidos por la aplicación del Deep Learning y dron?

**Anexo 4**

Validación del instrumento de recolección de datos



**UNIVERSIDAD NACIONAL DE JAÉN**  
CARRERA PROFESIONAL DE INGENIERIA MECÁNICA Y ELÉCTRICA



**OPINIÓN DE EXPERTOS A LA RECOLECCIÓN DE DATOS**

**PROYECTO DE TESIS: APLICACIÓN DE DEEP LEARNING Y DRON EN UNA LÍNEA DE TRANSMISIÓN PARA AUMENTAR LA PRODUCTIVIDAD EN DETECCIÓN DE FALLAS EN AISLADORES, JAÉN-CAJAMARCA.**

<b>EXPERTO:</b>		<i>Jannier Alberto Montenegro Suárez</i>														
<b>ESPECIALIDAD:</b>		<i>Ingeniero Mecánico Electricista.</i>														
<b>TELEFONO:</b>		<i>942480004</i>		<b>FECHA:</b>			<i>27/03/24</i>		<b>DNI:</b>		<i>41073708</i>		<b>FIRMA:</b>		<i>[Signature]</i>	
<b>Nº de pregunta</b>	<b>CRITERIOS</b>										<b>Observación</b>					
	<b>Claridad y comprensión</b>		<b>Coherencia y secuencia adecuada</b>		<b>Factibilidad de respuesta</b>		<b>Capacidad para generar datos útiles</b>		<b>Claridad del objetivo de la entrevista</b>							
	SI	NO	SI	NO	SI	NO	SI	NO	SI	NO						
1	X		X		X		X		X				—			
2	X		X		X		X		X				—			
3	X		X		X		X		X				—			
4	X		X		X		X		X				—			
5	X		X		X		X		X				—			
6	X		X		X		X		X				—			
7	X		X		X		X		X				—			
8	X		X		X		X		X				—			
<b>INDICADOR</b>																
<b>APLICABLE</b>		<i>SI</i>				<b>NO APLICABLE</b>				<i>---</i>						



**UNIVERSIDAD NACIONAL DE JAÉN**  
**CARRERA PROFESIONAL DE INGENIERIA MECÁNICA Y ELÉCTRICA**



**OPINIÓN DE EXPERTOS A LA RECOLECCIÓN DE DATOS**

**PROYECTO DE TESIS: DISEÑO Y CONSTRUCCIÓN DE UN DRON PARA LA DETECCIÓN DE FALLAS MECÁNICAS EN LÍNEAS DE TRANSMISIÓN EN JAÉN-CAJAMARCA.**

<b>EXPERTO:</b>		<i>Rolando René Rodríguez Medina</i>														
<b>ESPECIALIDAD:</b>		<i>Ingeniero Mecánico Electricista</i>														
<b>TELEFONO:</b>		<i>943673977</i>		<b>FECHA:</b>			<i>01/04/2024</i>		<b>DNI:</b>		<i>40256781</i>		<b>FIRMA:</b>			
N° de pregunta	<b>CRITERIOS</b>										Observación					
	Claridad y comprensión		Coherencia y secuencia adecuada		Factibilidad de respuesta		Capacidad para generar datos útiles		Claridad del objetivo de la entrevista							
	SI	NO	SI	NO	SI	NO	SI	NO	SI	NO						
1	X		X		X		X		X							
2	X		X		X		X		X							
3	X		X		X		X		X							
4	X		X		X		X		X							
5	X		X		X		X		X							
6	X		X		X		X		X							
7	X		X		X		X		X							
8	X		X		X		X		X							
<b>INDICADOR</b>																
APLICABLE			<i>Si</i>						NO APLICABLE			---				



UNIVERSIDAD NACIONAL DE JAÉN  
CARRERA PROFESIONAL DE INGENIERIA MECÁNICA Y ELÉCTRICA



OPINIÓN DE EXPERTOS A LA RECOLECCIÓN DE DATOS

PROYECTO DE TESIS: APLICACIÓN DE DEEP LEARNING Y DRON EN UNA LÍNEA DE TRANSMISIÓN PARA AUMENTAR LA PRODUCTIVIDAD EN DETECCIÓN DE FALLAS EN AISLADORES, JAÉN-CAJAMARCA.

EXPERTO:	Jaime Odar Honorio Acosta										
ESPECIALIDAD:	Ingeniería Mecánica										
TELEFONO:	968065405		FECHA:	04/04/2024		DNI:	18847647		FIRMA:		
N° de pregunta	CRITERIOS										Observación
	Claridad y comprensión		Coherencia y secuencia adecuada		Factibilidad de respuesta		Capacidad para generar datos útiles		Claridad del objetivo de la entrevista		
	SI	NO	SI	NO	SI	NO	SI	NO	SI	NO	
1	X		X		X		X		X		
2	X		X		X		X		X		
3	X		X		X		X		X		
4	X		X		X		X		X		
5	X		X		X		X		X		
6	X		X		X		X		X		
7	X		X		X		X		X		
8	X		X		X		X		X		
INDICADOR											
APLICABLE			SI			NO APLICABLE					

## Anexo 5

### Desarrollo de entrevista estructurada



UNIVERSIDAD NACIONAL DE JAÉN  
CARRERA PROFESIONAL DE INGENIERÍA  
MECÁNICA Y ELÉCTRICA



PROYECTO DE TESIS: APLICACIÓN DE DEEP LEARNING Y DRON EN UNA LÍNEA DE TRANSMISIÓN PARA AUMENTAR LA PRODUCTIVIDAD EN DETECCIÓN DE FALLAS EN AISLADORES, JAÉN-CAJAMARCA.			
ENTREVISTA ESTRUCTURADA			
REGIÓN: Cajamarca	PROVINCIA: Jaén	LUGAR: Jaén	FECHA: 15-07-2025
ENTREVISTADOR:	Salomón Cubas Quevedo		DNI: 47968487
ENTREVISTADO 1:	Alexis Saucedo Manayay		DNI: 75451648
ENTREVISTADO 2:	Christian Zelada Benavides		DNI: 77300225
ESPECIALIDAD 1:	Electricidad Industrial - Encargado de área		
ESPECIALIDAD 2:	Técnico Electricista - Técnico		

**\*\*Las preguntas del 1 al 6 se dirigen específicamente al equipo técnico y al responsable del área de mantenimiento, mientras que las preguntas 7 y 8 están destinadas exclusivamente al responsable del área de mantenimiento.**

**1. ¿Cómo se realizan las inspecciones de mantenimiento preventivo para detectar las fallas en aisladores en las líneas de transmisión en la actualidad?**

- **Técnico:** Actualmente se realizan de manera visual, desde el suelo, utilizando cámaras de celular para tomar fotografías de la base de la estructura y de la torre.

- **Encargado:** El procedimiento es rutinario; el personal recorre las estructuras y hace la inspección ocular. Cualquier hallazgo se registra con fotos, que luego se incluyen en los informes de mantenimiento.

**2. ¿De cuántos técnicos requiere para una inspección y detección de fallas en aisladores por estructura?**

- **Técnico:** Normalmente trabajamos en cuadrillas de 5 personas: 2 técnicos, 2 apoyos y 1 conductor.

- **Encargado:** Es necesario ese equipo mínimo, porque los técnicos hacen la inspección, los apoyos se encargan de la limpieza de servidumbre y el conductor facilita la movilidad de la cuadrilla.

**3. ¿Cuánto tiempo dura realizar este trabajo de inspección?**

- **Técnico:** En promedio, de 23 minutos por torre.

- **Encargado:** Ese tiempo puede variar según el acceso, pero generalmente no excede los 23 minutos.

**4. ¿Cuál es la cantidad de inspecciones que pueden realizar en una jornada de trabajo de 8 horas?**

- **Técnico:** Logramos cubrir alrededor de 8 a 10 torres por día.

- **Encargado:** Sí, ese es el promedio establecido en las jornadas diarias.

**5. ¿Cuáles son los posibles riesgos a los que se enfrenta el personal técnico durante las actividades de inspección?**

- **Técnico:** Riesgos de caídas por terreno accidentado, riesgos de electrocución por mal aterramiento de las estructuras, mordeduras de animales y exposición prolongada al sol.

- **Encargado:** También está el riesgo de tránsito en zonas alejadas y la fatiga del personal por caminar largas distancias en áreas de difícil acceso.

**6. ¿Considera que la productividad podría aumentar mediante la aplicación del Deep Learning y dron?**

- **Técnico:** Sí, porque los drones llegarían a puntos donde nosotros no podemos observar desde el suelo, y con las imágenes procesadas sería más rápido identificar fallas.

- **Encargado:** Definitivamente sí. Se reduciría el tiempo de inspección y aumentaríamos la cobertura diaria, mejorando la productividad.

**7. ¿Cuáles son los costos asociados a la inspección tradicional por jornada de trabajo?**

- **Encargado:** Los costos diarios que los técnicos reciben es de S/. 100, los apoyos S/. 60 y el conductor S/. 53.33. Además, hay gastos de combustible (S/. 50 diarios) y viáticos de alimentación (S/. 50 diarios/almuerzo).

**8. ¿Considera que los costos de inspección se verían disminuidos por la aplicación del Deep Learning y dron?**

- **Encargado:** Sí, a mediano plazo el costo sería más bajo, ya que los drones optimizarían los recursos, disminuirían el tiempo en campo y reducirían la necesidad de desplazar cuadrillas grandes.

  
DNI: 77 300225

  
DNI: 75451648



PROYECTO DE TESIS: APLICACIÓN DE DEEP LEARNING Y DRON EN UNA LÍNEA DE TRANSMISIÓN PARA AUMENTAR LA PRODUCTIVIDAD EN DETECCIÓN DE FALLAS EN AISLADORES, JAÉN-CAJAMARCA.

ENTREVISTA ESTRUCTURADA

REGIÓN: Cajamarca	PROVINCIA: Jaén	LUGAR: Jaén	FECHA: 20-01-2026
ENTREVISTADOR:	Salomón Cubas Quevedo		DNI: 47968487
ENTREVISTADO 1:	Exsar Marcos Mendoza Silva		DNI: 74731170
ENTREVISTADO 2:	Ian Thor Lenon Saavedra Segura		DNI: 72686132
ESPECIALIDAD 1:	Técnico en Mantenimiento de Sistemas Eléctricos		
ESPECIALIDAD 2:	Técnico Electricista.		

**\*\*Las preguntas del 1 al 6 se dirigen específicamente al equipo técnico y al responsable del área de mantenimiento, mientras que las preguntas 7 y 8 están destinadas exclusivamente al responsable del área de mantenimiento.**

**1. ¿Cómo se realizan las inspecciones de mantenimiento preventivo para detectar las fallas en aisladores en las líneas de transmisión en la actualidad?**

Actualmente las inspecciones se realizan de manera visual desde el suelo. Los técnicos observan los aisladores apoyándose con cámaras de celular para tomar fotografías de la base de la estructura y de la torre. Nosotros como personal de apoyo colaboramos asegurando el área y facilitando el acceso para que la inspección pueda realizarse de forma segura.

**2. ¿De cuántos técnicos requiere para una inspección y detección de fallas en aisladores por estructura?**

Generalmente se trabaja con una cuadrilla de cinco personas: dos técnicos, dos apoyos y un conductor. Los técnicos realizan la evaluación directa de los aisladores, mientras que los apoyos asistimos en labores complementarias y el conductor se encarga del traslado.

**3. ¿Cuánto tiempo dura realizar este trabajo de inspección?**

En promedio, la inspección de cada torre dura aproximadamente entre 20 y 23 minutos, dependiendo del acceso al lugar y de las condiciones del terreno.

**4. ¿Cuál es la cantidad de inspecciones que pueden realizar en una jornada de trabajo de 8 horas?**

En una jornada de 8 horas se pueden inspeccionar entre 8 y 10 torres, aunque puede variar según la distancia entre estructuras y la dificultad del acceso.

**5. ¿Cuáles son los posibles riesgos a los que se enfrenta el personal técnico durante las actividades de inspección?**


Los riesgos principales son caídas por terrenos irregulares, exposición prolongada al sol, mordeduras de animales y posibles riesgos eléctricos si existiera algún problema en la puesta a tierra. También existe desgaste físico por caminatas largas en zonas de difícil acceso.

**6. ¿Considera que la productividad podría aumentar mediante la aplicación del Deep Learning y dron?**

Si, consideramos que sí aumentaría la productividad, porque el dron permitiría obtener imágenes más detalladas y desde mejores ángulos.

**7. ¿Cuáles son los costos asociados a la inspección tradicional por jornada de trabajo?**

**8. ¿Considera que los costos de inspección se verían disminuidos por la aplicación del Deep Learning y dron?**

  
74731110

  
72686132

## Anexo 6

### Autorización de Electro Oriente para el vuelo del dron



Firmado Digitalmente por:  
PEREZ RAVELO Cesar Augusto FAU  
20103795631 hard  
Razón: SOY AUTOR DEL DOCUMENTO  
Ubicación: ELOR S.A.  
Fecha: 30/12/2024 14:29:17


"Año del Bicentenario, de la consolidación de nuestra Independencia, y de la conmemoración de las heroicas batallas de Junín y Ayacucho"

LORETO, 30 de diciembre de 2024

GW-3544-2024

Expediente: 20240110012883

Señor(a)  
UNIVERSIDAD NACIONAL DE JAÉN  
CARRETERA JAEN - SAN IGNACIO - , YANAYACU  
Jaén - Jaén  
Cajamarca .-



Asunto : SOLICITUD DE PERMISO PARA TOMAS FOTOGRÁFICAS  
Referencia : a) OFICIO N°989-2024-UNJ/VPA/FI  
b) [GWT]

De mi consideración:

Por medio de la presente me dirijo a usted, para expresarle mi cordial saludo; asimismo con respecto al documento de la referencia, se informa que, por tratarse de actividades, en la parte exterior de nuestra infraestructura eléctrica, línea de transmisión, subestaciones de potencia Jaén y Nueva Jaén respectivamente, es procedente realizar los trabajos que tienen programados para su proyecto de tesis.

Sin embargo, se recomienda que el operador del equipo Dron, realice sus maniobras fuera de la faja de servidumbre, es decir, a 8 metros del eje de línea.

Sin otro particular, me suscribo.

Atentamente,

**CESAR AUGUSTO PEREZ RAVELO**  
GERENTE REGIONAL AMAZONAS CAJAMARCA (e)




Según lo dispuesto por el Art. 25 de D.S. 070-2013-PCM y la Tercera Disposición Complementaria Final del D.S. 026-2016-PCM. Puede validar la autenticidad e integridad del documento generado a través del código QR ubicado en la parte inferior izquierda del presente documento o colocando la siguiente dirección en la barra del navegador: <http://www.elor.com.pe:85/SistemaCasillaVerificacion> e ingresando la siguiente clave TPLE5T.

Para un próximo trámite, señalar el número de expediente: 20240110012883  
Augusto Freyre N° 1168 – Iquitos  
Central Telefónica N° 065-253500

1 de 1

## Anexo 7

### Autorización de salida de dron – UNJ

**UNJ**  
UNIVERSIDAD  
NACIONAL DE JAÉN

**FACULTAD DE INGENIERÍA**  
**DEPARTAMENTO ACADÉMICO DE INGENIERÍA CIVIL**

"Año de la recuperación y consolidación de la economía peruana"

# CARGO

Jaén, 09 de junio de 2025

**OFICIO N°077-2025-UNJ/FI/DAIC**      **EXP N°: 00893059**

Señor  
**Dr. Segundo Sánchez Tello**  
Coordinador de la Facultad de Ingeniería  
Universidad Nacional de Jaén  
**Presente.** -

**ASUNTO:**      **AUTORIZA SALIDA DE EQUIPO DEL LABORATORIO DE TOPOGRAFÍA PARA QUE SE PROSIGA CON LOS TRAMITES CORRESPONDIENTES**

**REFERENCIA:**      **OFICIO N°004-2025-UNJ/FI/DAIC/LT**  
**CARTA N°008-2025-UNJ/FI/DAIC**  
**CARTA S/N**  
**RESOLUCIÓN N°754-2024-UNJ/FI**

Me dirijo a usted, para expresarle mi saludo cordial y al mismo tiempo en atención a los documentos referenciados, se autoriza la salida del equipo para la ejecución de tesis titulado "Aplicación de DEEP LEARNING y dron en una línea de transmisión para aumentar la productividad en detección de fallas de aisladores, Jaén - Cajamarca", a ejecutar por los tesisistas: Juan Eduardo Laban Chuquipoma y Salomón Cubas Quevedo, teniendo como asesores a los docentes: Luis Miguel Llanos Sánchez y Ricardo Ángel Shimabuku Ysa, según la programación:

FECHA	HORARIO	LUGAR
16/06/2025	08:30 AM – 11:00 AM	Intersección de Av. Circunvalación y calle Unión – sector Miraflores Jaén
20/06/2025	08:30 AM – 11:00 AM	Av. Circunvalación – Sector Los Sauces – Sector La Colina
23/06/2025	08:30 AM – 11:00 AM	Subestación de potencia Nueva Jaén – Sector El Huito – Jaén

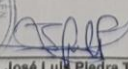
En tal sentido, se solicita remitir a la oficina de administración para el trámite correspondiente para la salida de dicho equipo que se detalla a continuación:

Equipo	Código patrimonial
Vehículo aéreo no tripulado DRONE	670491990005

Sin otro particular, reitero las muestras de mi consideración y estima.

UNIVERSIDAD NACIONAL DE JAÉN  
OFICINA DE CONTROL PATRIMONIAL  
FECHA: 10 JUN 2025  
FOLIOS: 02  
HORA: 03:38 P.M.

Atentamente,

  
**Dr. José Luis Piedra Tineo**  
Responsable (e)  
Departamento Académico de Ingeniería Civil

UNIVERSIDAD NACIONAL DE JAÉN  
FACULTAD DE INGENIERÍA  
10 JUN 2025  
Exp. N° ..... Folios 09-  
3:13pm

C.c.  
Unidad de Control Patrimonial  
Arzayo  
Carmen R.

SOLIDARIA - SALUDABLE - SOSTENIBLE  
[www.unj.edu.pe](http://www.unj.edu.pe)

CONTACTO  
[Departamento.academico@unj.edu.pe](mailto:Departamento.academico@unj.edu.pe)

EMAIL  
[Departamento.academico@unj.edu.pe](mailto:Departamento.academico@unj.edu.pe)

DIRECCIÓN  
Carretera Jaén - San Agustín Km. 24  
Sector Píscar

## Anexo 8

### Especificaciones técnicas del dron



# PHANTOM 4 RTK

ESPECIFICACIONES

Aeronave	Peso de despegue	1391 g
	Altura máx. de servicio sobre el nivel del mar	6000 m (19685 pies)
	Tiempo máx. de vuelo	30 minutos aprox.
	Rango de temperatura de funcionamiento	0 a 40 °C (32 a 104 °F)
	Rango de precisión de vuelo estacionario	RTK activo y funcionando: Vertical: ±0.1 m; Horizontal: ±0.1 m RTK desactivado Vertical: ±0.1 m (con posicionamiento visual); ±0.5 m (con posicionamiento GNSS) Horizontal: ±0.3 m (con posicionamiento visual); ±1.5 m (con posicionamiento GNSS)
	Desvío de posición de imagen	Para compensar la diferencia entre el centro de la cámara y el centro de fase de la antena D-RTK, se ha realizado un ajuste (36, 0 y 192 mm) a las coordenadas de la imagen en formato Exif. Los ejes positivos x, y, z del cuerpo de la aeronave apuntan al frente, a la derecha y hacia abajo de la aeronave respectivamente.
GNSS	Módulo GNSS de alta sensibilidad y frecuencia única	GPS+BeiDou+Galileo (Asia) GPS+GLONASS+Galileo (otras regiones)
	GNSS RTK de alta precisión multisistema y multifrecuencia	Frecuencia utilizada: GPS: L1/L2; GLONASS: L1/L2; BeiDou: B1/B2; Galileo: E1/E5a Precisión de velocidad: 0.03 m/s
Cámara	Sensor	1" CMOS Píxeles efectivos: 20 MP
	Objetivo	FOV (campo de visión) 84°, 8.8 mm [24 mm (equivalente a formato de 35 mm)] f/2.8 - f/11; enfoque a 1 m - ∞
	Rango ISO	Vídeo: 100 - 3200 (auto) 100 - 6400 (manual) Foto: 100 - 3200 (auto) 100 - 12800 (manual)
	Velocidad de obturación	Velocidad del obturador electrónico: 8 - 1/8000 s Velocidad obturador mecánico: 8 - 1/2000 s
	Tamaño de fotografía	3:2 5472×3648 4:3 4864×3648
	Tarjetas SD compatibles	MicroSD, Capacidad Máx.: 128 GB. Clase 10 ó UHS-1 valoración requerida

Fuente: Adaptado de AI- Top Topografía. SA. <https://al-top.com/wp-content/uploads/2019/01/DJI-Phantom-4-RTK.pdf>

## Anexo 9

### *Inspección de aisladores con dron*



Fuente: Elaboración propia

## Anexo 10

### Preprocesamiento de imágenes

#### Librerías

```
from google.colab import drive
drive.mount('/content/drive')
```

Mounted at /content/drive

```
import os
import numpy as np
import numpy as np
import cv2
import matplotlib.pyplot as plt
%matplotlib inline
```

#### Cantidad de imágenes

```
#Cantidad de imágenes segun cada categoria:
!ls /content/drive/MyDrive/"CLASIFICACION DE AISLADORES"/"1. AISLADORES BUENOS" | wc -l
!ls /content/drive/MyDrive/"CLASIFICACION DE AISLADORES"/"2. AISLADORES SUCIOS" | wc -l
!ls /content/drive/MyDrive/"CLASIFICACION DE AISLADORES"/"3. AISLADORES DAÑADOS" | wc -l
```

981  
330  
705

Fuente: Elaboración propia

## Anexo 11

### Aisladores buenos

```
from PIL import Image
import os
from tqdm import tqdm

def optimizar_jpg(carpetas_entrada, carpeta_salida, calidad=90):
    if not os.path.exists(carpetas_salida):
        os.makedirs(carpetas_salida)

    archivos_jpg = [f for f in os.listdir(carpetas_entrada) if f.lower().endswith((".jpg", ".jpeg"))]

    total_original = 0
    total_optimizado = 0

    with tqdm(total=len(archivos_jpg), desc="Procesando imágenes", unit="img") as barra:
        for i, nombre_archivo in enumerate(archivos_jpg):
            ruta_entrada = os.path.join(carpetas_entrada, nombre_archivo)
            nombre_salida = f"asb_{i+1:04d}.jpg"
            ruta_salida = os.path.join(carpetas_salida, nombre_salida)

            with Image.open(ruta_entrada) as img:
                img = img.convert("RGB")
                ancho, alto = img.size

                if ancho > 900:

                    izquierda = min(1000, ancho - 1)
                    derecha = max(ancho - 900, izquierda + 1)
                    superior = min(500, alto - 1)
                    inferior = max(alto - 500, superior + 1)

                    if izquierda < derecha and superior < inferior:
                        img = img.crop((izquierda, superior, derecha, inferior))
                    else:

                        img = img.resize((900, int(alto * 900 / ancho)), Image.Resampling.LANCZOS)
```

```

        if img.size[0] > 0 and img.size[1] > 0:
            img.save(ruta_salida, "JPEG", quality=calidad)
            total_original += os.path.getsize(ruta_entrada)
            total_optimizado += os.path.getsize(ruta_salida)
        else:
            print(f"[Advertencia] La imagen resultante de {nombre_archivo} tiene tamaño cero después del procesamiento.")

        barra.update(1)

    ahorro = (1 - total_optimizado / total_original) * 100 if total_original > 0 else 0

carpeta_original = "/content/drive/MyDrive/CLASIFICACION DE AISLADORES/1. AISLADORES BUENOS"
carpeta_optimizadas = "/content/drive/MyDrive/1.Aisladores_Buenos"

optimizar_jpg(carpeta_original, carpeta_optimizadas, calidad=100)

```

---

```

... Procesando imágenes: 100% ██████████ 1069/1069 [08:24<00:00, 2.12img/s]

```

```

#Mostrar algunas imagenes con pyplot
import os
import matplotlib.pyplot as plt
import matplotlib.image as mpimg

plt.figure(figsize=(15,15))

carpeta = '/content/drive/MyDrive/1.Aisladores_Buenos'

imagenes = os.listdir(carpeta)
for i, nombreimg in enumerate(imagenes[:25]):
    plt.subplot(5,5,i+1)
    imagen = mpimg.imread(carpeta + '/' + nombreimg)
    plt.imshow(imagen)
plt.savefig('Aisladores Buenos.jpg', dpi=900)

```



Fuente: Elaboración propia

## Anexo 12

### Aisladores sucios

#### Conversión de formato a JPG

```
!pip install piexif Pillow tqdm

import os
from PIL import Image
import piexif
from tqdm import tqdm

def convertir_imagenes(carpeta_entrada, carpeta_salida, prefijo_salida="ass_"):
    if not os.path.exists(carpeta_salida):
        os.makedirs(carpeta_salida)

    archivos = [f for f in os.listdir(carpeta_entrada) if f.lower().endswith(('.heic', '.jpeg', '.jpg'))]

    for i, nombre_archivo in enumerate(tqdm(archivos, desc="Convirtiendo imágenes", unit="imagen")):
        ruta_entrada = os.path.join(carpeta_entrada, nombre_archivo)
        nuevo_nombre = f'ass_{i+1:03d}.jpg'
        ruta_salida = os.path.join(carpeta_salida, nuevo_nombre)

        try:
            img = Image.open(ruta_entrada)

            if img.mode != 'RGB':
                img = img.convert('RGB')

            try:
                exif_dict = piexif.load(ruta_entrada)
                exif_bytes = piexif.dump(exif_dict)
            except Exception as e:
                exif_bytes = None
            print(f"[Advertencia] No se pudieron cargar los metadatos Exif de {nombre_archivo}: {e}")

            img.save(ruta_salida, "jpeg", exif=exif_bytes)
        except Exception as e:
            print(f"[Error] No se pudo procesar {nombre_archivo}: {e}")

# === USO ===
carpeta_original_convertir = "/content/drive/MyDrive/CLASIFICACION DE AISLADORES/2. AISLADORES SUCIOS"
carpeta_convertidas_salida = "/content/drive/MyDrive/2.Aisladores_Sucios"

convertir_imagenes(carpeta_original_convertir, carpeta_convertidas_salida, prefijo_salida="ass_")
```

```
... Requirement already satisfied: piexif in /usr/local/lib/python3.11/dist-packages (1.1.3)
Requirement already satisfied: Pillow in /usr/local/lib/python3.11/dist-packages (11.3.0)
Requirement already satisfied: tqdm in /usr/local/lib/python3.11/dist-packages (4.67.1)
Convirtiendo imágenes: 100%|██████████| 330/330 [00:08<00:00, 39.40imagen/s]
```

#### Aumento de imágenes

```
import os
import random
from PIL import Image

input_dir = '/content/drive/MyDrive/2.Aisladores_Sucios'
output_dir = '/content/drive/MyDrive/2.Aisladores_Sucios'
os.makedirs(output_dir, exist_ok=True)

image_files = [f for f in os.listdir(input_dir) if f.lower().endswith(('.jpg', '.jpeg', '.png'))]
subset_size = int(0.5 * len(image_files))
selected_files = random.sample(image_files, subset_size)

for i, filename in enumerate(selected_files):
    img_path = os.path.join(input_dir, filename)
    img = Image.open(img_path)

    # Redimensionar proporcionalmente al ancho 640
    width_percent = 640 / float(img.size[0])
    height_size = int(float(img.size[1]) * width_percent)
    img_resized = img.resize((640, height_size), Image.LANCZOS)

    new_name = f'assa_{i+1:03d}.jpg'
    save_path = os.path.join(output_dir, new_name)

    img_resized.save(save_path, quality=100, optimize=True)
#Plt.savefig('Aisladores Sucios.jpg', dpi=900)

print(f"{subset_size} imágenes redimensionadas guardadas en: {output_dir}")
```

```
165 imágenes redimensionadas guardadas en: /content/drive/MyDrive/2.Aisladores_Sucios
```

## Redimensionamiento a 640 px

```
!pip install tqdm
import os
from PIL import Image
from tqdm import tqdm

# === CONFIGURACIÓN ===
input_dir = '/content/drive/MyDrive/2.Aisladores_Sucios'
output_dir = '/content/drive/MyDrive/2.Aisladores_Sucios'
prefijo_nombre = 'ass_' # Cambia si querés otro prefijo
ancho_objetivo = 640 # Ancho deseado en píxeles

# Crear carpeta de salida
os.makedirs(output_dir, exist_ok=True)

# Listar todas las imágenes compatibles
image_files = [f for f in os.listdir(input_dir) if f.lower().endswith(('.jpg', '.jpeg', '.png'))]

# Barra de progreso
for i, filename in enumerate(tqdm(image_files, desc="Redimensionando", unit="imagen")):
    try:
        img_path = os.path.join(input_dir, filename)
        img = Image.open(img_path)

        # Redimensionar proporcionalmente al ancho objetivo
        width_percent = ancho_objetivo / float(img.size[0])
        height_size = int(float(img.size[1]) * width_percent)
        img_resized = img.resize((ancho_objetivo, height_size), Image.LANCZOS)

        # Guardar
        new_name = f'ass_{i+1:03d}.jpg'
        save_path = os.path.join(output_dir, new_name)

        img_resized.save(save_path, quality=100, optimize=True)
    except Exception as e:
        print(f"[Error] No se pudo procesar {filename}: {e}")

... Requirement already satisfied: tqdm in /usr/local/lib/python3.11/dist-packages (4.67.1)
Redimensionando: 100%|██████████| 495/495 [00:22<00:00, 22.38imagen/s]

#Mostrar algunas imagenes con pyplot
import os
import matplotlib.pyplot as plt
import matplotlib.image as mpimg

plt.figure(figsize=(15,15))

carpeta = "/content/drive/MyDrive/2.Aisladores_Sucios"

imagenes = os.listdir(carpeta)
for i, nombreimg in enumerate(imagenes[:25]):
    plt.subplot(5,5,i+1)
    imagen = mpimg.imread(carpeta + '/' + nombreimg)
    plt.imshow(imagen)
plt.savefig('Aisladores Sucios.jpg', dpi=1200)
```



Fuente: Elaboración propia

## Anexo 13

### Aisladores Dañados

```
!pip install piexif Pillow tqdm

import os
from PIL import Image
import piexif
from tqdm import tqdm

def convertir_imagenes(carpeta_entrada, carpeta_salida, prefijo_salida="asd_"):
    if not os.path.exists(carpeta_salida):
        os.makedirs(carpeta_salida)

    archivos = [f for f in os.listdir(carpeta_entrada) if f.lower().endswith(('.HEIC', '.jpeg', '.jpg'))]

    for i, nombre_archivo in enumerate(tqdm(archivos, desc="Convirtiendo imágenes", unit="imagen")):
        ruta_entrada = os.path.join(carpeta_entrada, nombre_archivo)
        nuevo_nombre = f'asd_{i+1:03d}.jpg'
        ruta_salida = os.path.join(carpeta_salida, nuevo_nombre)

        try:
            img = Image.open(ruta_entrada)

            if img.mode != 'RGB':
                img = img.convert('RGB')

            try:
                exif_dict = piexif.load(ruta_entrada)
                exif_bytes = piexif.dump(exif_dict)
            except Exception as e:
                exif_bytes = None
                print(f"[Advertencia] No se pudieron cargar los metadatos Exif de {nombre_archivo}: {e}")

            img.save(ruta_salida, "jpeg", exif=exif_bytes)
        except Exception as e:
            print(f"[Error] No se pudo procesar {nombre_archivo}: {e}")

# === USO ===
carpeta_original_convertir = "/content/drive/MyDrive/CLASIFICACION DE AISLADORES/3. AISLADORES DAÑADOS"
carpeta_convertidas_salida = "/content/drive/MyDrive/3. Aisladores_Dañados"

convertir_imagenes(carpeta_original_convertir, carpeta_convertidas_salida, prefijo_salida="asd_")
```

---

```
*** Requirement already satisfied: piexif in /usr/local/lib/python3.11/dist-packages (1.1.3)
Requirement already satisfied: Pillow in /usr/local/lib/python3.11/dist-packages (11.3.0)
Requirement already satisfied: tqdm in /usr/local/lib/python3.11/dist-packages (4.67.1)
Convirtiendo imágenes: 100%|██████████| 510/510 [00:55<00:00, 9.12imagen/s]
```

### Redimensionamiento a 640 px

```
!pip install tqdm

import os
from PIL import Image
from tqdm import tqdm

# === CONFIGURACIÓN ===
input_dir = '/content/drive/MyDrive/3.Aisladores_Dañados'
output_dir = '/content/drive/MyDrive/3.Aisladores_Dañados'
prefijo_nombre = 'asd_' # Cambia si querés otro prefijo
ancho_objetivo = 640 # Ancho deseado en pixeles

# Crear carpeta de salida si no existe
os.makedirs(output_dir, exist_ok=True)

# Listar todas las imágenes compatibles
image_files = [f for f in os.listdir(input_dir) if f.lower().endswith(('.jpg', '.jpeg', '.png'))]

# Procesar todas las imágenes con barra de progreso
for i, filename in enumerate(tqdm(image_files, desc="Redimensionando", unit="imagen")):
    try:
        img_path = os.path.join(input_dir, filename)
        img = Image.open(img_path)

        # Redimensionar proporcionalmente al ancho objetivo
        width_percent = ancho_objetivo / float(img.size[0])
        height_size = int(float(img.size[1]) * width_percent)
        img_resized = img.resize((ancho_objetivo, height_size), Image.LANCZOS)

        # Guardar con nuevo nombre
        new_name = f'asd_{i+1:03d}.jpg'
        save_path = os.path.join(output_dir, new_name)
```

```
img_resized.save(save_path, quality=100, optimize=True)
except Exception as e:
    print(f"[Error] No se pudo procesar {filename}: {e}")
```

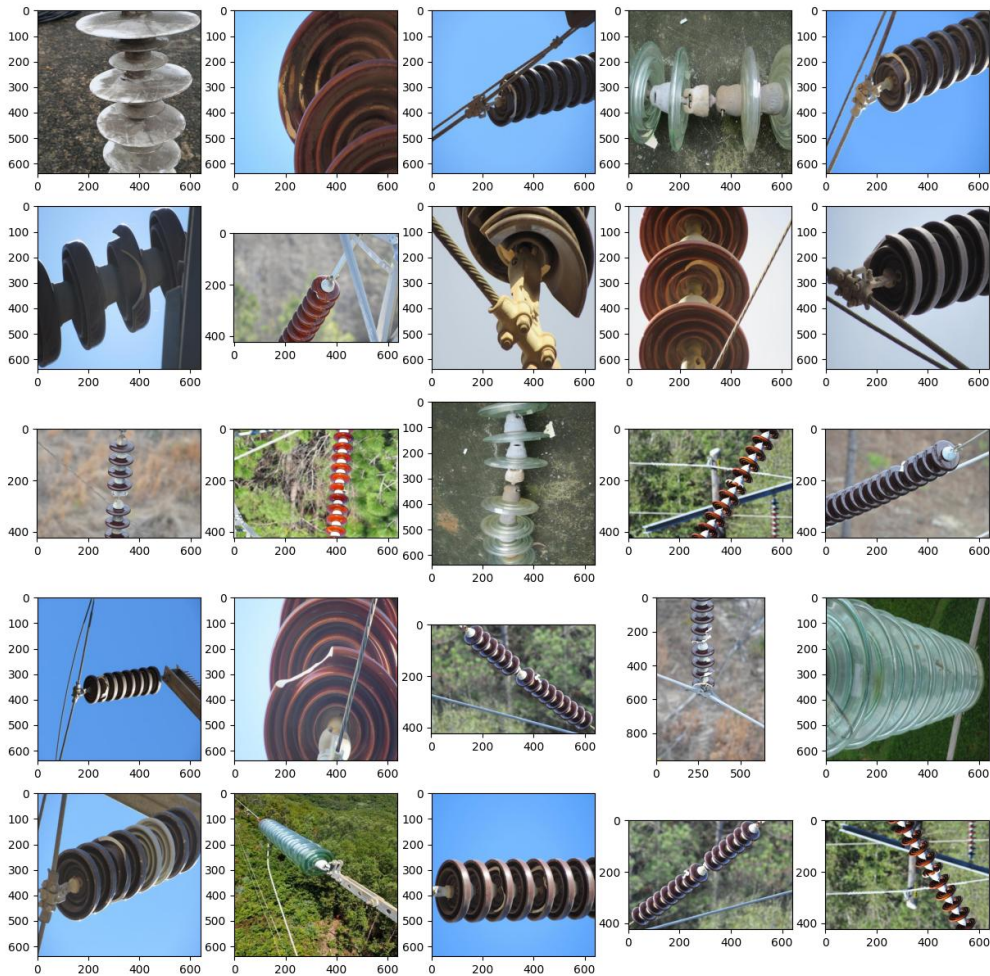
```
*** Requirement already satisfied: tqdm in /usr/local/lib/python3.11/dist-packages (4.67.1)
    Redimensionando: 100%|██████████| 510/510 [01:27<00:00, 5.81imagen/s]
```

```
#Mostrar algunas imagenes con pyplot
import os
import matplotlib.pyplot as plt
import matplotlib.image as mpimg

plt.figure(figsize=(15,15))

carpeta = '/content/drive/MyDrive/3.Aisladores_Dañados'
```

```
imagenes = os.listdir(carpeta)
for i, nombreimg in enumerate(imagenes[:25]):
    plt.subplot(5,5,i+1)
    imagen = mpimg.imread(carpeta + '/' + nombreimg)
    plt.imshow(imagen)
plt.savefig('Aisladores Dañados.jpg', dpi=900)
```



## Base de datos

```
#Base de datos final
ls /content/drive/MyDrive/1.Aisladores_Buenos | wc -l
ls /content/drive/MyDrive/2.Aisladores_Sucios | wc -l
ls /content/drive/MyDrive/3.Aisladores_Dañados | wc -l
```

```
1069
660
510
```

Fuente: Elaboración propia

## Anexo 14

### Preparación de Dataset

```
from google.colab import drive
drive.mount('/content/drive')
```

Mounted at /content/drive

```
import zipfile
from tqdm import tqdm

zip_path = "/content/drive/MyDrive/project-ea.zip" # ruta al archivo .zip
output_dir = "/content/drive/MyDrive/project-ea"

with zipfile.ZipFile(zip_path, 'r') as zip_ref:
    files = zip_ref.namelist()
    for file in tqdm(files, desc="Descomprimiendo", unit="archivo"):
        zip_ref.extract(file, output_dir)
```

Descomprimiendo: 100%|██████████| 4306/4306 [03:50<00:00, 18.72archivo/s]

Fuente: Elaboración propia

## Anexo 15

### *Etiquetado de aisladores en Label Studio*

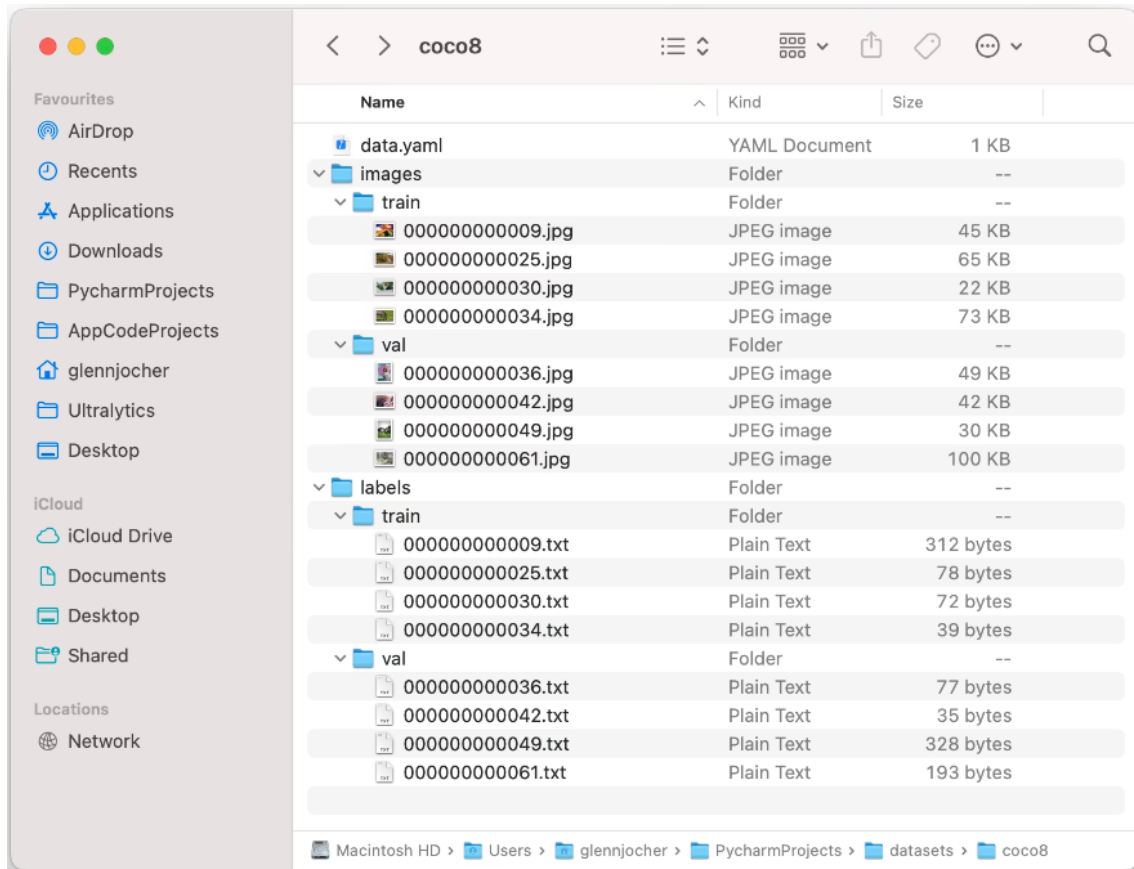
0 0.7336209698868171 0.7572992700729927 0.20215333392436732 0.1642335766423358  
0 0.10107666696218366 0.728102189781022 0.16954795748495324 0.14233576642335763  
0 0.8412187121368835 0.9288321167883211 0.0912950540303595 0.07664233576642332



Fuente: Elaboración propia

## Anexo 16

### Estructura del Dataset



Fuente: Documentación de Ultralytics YOLO.

<https://www.51cto.com/aigc/2600.html#ultralytics-yolo-format>

## Anexo 17

### Creación de la lista de clases data.yaml

```
▶ import os
import yaml

# Datos para el YAML
data = {
    'path': '/content/datasets',
    'train': 'images/train',
    'val': 'images/val',
    'test': 'images/test',
    'names': {
        0: "Bueno",
        1: "Roto/Flameado",
        2: "Sucio"
    }
}

# Crear carpeta
os.makedirs('/content/datasets', exist_ok=True)

# Guardar el YAML
with open('/content/datasets/data.yaml', 'w') as file:
    yaml.dump(
        data,
        file,
        default_flow_style=False,
        sort_keys=False
    )
```

Fuente: Elaboración propia

## Anexo 18

### División del conjunto de datos, entrenamiento y validación

```
import os
import shutil
import random
from tqdm import tqdm # Barra de progreso

# Carpeta de origen
source_images_dir = '/content/drive/MyDrive/project-ea/images'
source_labels_dir = '/content/drive/MyDrive/project-ea/labels'

# Carpeta base de destino
base_dir = '/content/datasets'
images_dir = os.path.join(base_dir, 'images')
labels_dir = os.path.join(base_dir, 'labels')

# Crear estructura de carpetas
subfolders = ['train', 'val']
for subfolder in subfolders:
    os.makedirs(os.path.join(images_dir, subfolder), exist_ok=True)
    os.makedirs(os.path.join(labels_dir, subfolder), exist_ok=True)

# Obtener lista de imágenes desde la carpeta de origen
image_files = [f for f in os.listdir(source_images_dir) if f.lower().endswith('.jpg')]

# Emparejar imagen con su etiqueta correspondiente
image_label_pairs = [
    (img, img.replace('.jpg', '.txt'))
    for img in image_files
    if os.path.exists(os.path.join(source_labels_dir, img.replace('.jpg', '.txt')))]

# Dividir en train, val y test (80%, 20%)
random.shuffle(image_label_pairs)
train_split = int(0.8 * len(image_label_pairs))
val_split = int(0.2 * len(image_label_pairs))

train_pairs = image_label_pairs[:train_split]
val_pairs = image_label_pairs[train_split:train_split + val_split]
test_pairs = image_label_pairs[train_split + val_split:]

# Función para copiar imágenes y etiquetas con barra de progreso
def copy_files(pairs, subset):
    for image, label in tqdm(pairs, desc=f" {subset}", unit="archivo"):
        shutil.copy(os.path.join(source_images_dir, image),
                    os.path.join(images_dir, subset, image))
        shutil.copy(os.path.join(source_labels_dir, label),
                    os.path.join(labels_dir, subset, label))

copy_files(train_pairs, 'train')
copy_files(val_pairs, 'val')
```

---

```
... train: 100%|██████████| 1720/1720 [00:50<00:00, 34.14archivo/s]
    val: 100%|██████████| 430/430 [00:18<00:00, 23.56archivo/s]
```

Fuente: Elaboración propia

# Anexo 19

## Entrenamiento del YOLOv11 con el Dataset

• pip install ultralytics

```
... Collecting ultralytics
  Downloading ultralytics-8.3.221-py3-none-any.whl.metadata (37 kB)
Requirement already satisfied: numpy>=1.23.0 in /usr/local/lib/python3.12/dist-packages (from ultralytics) (2.0.2)
Requirement already satisfied: matplotlib>=3.3.0 in /usr/local/lib/python3.12/dist-packages (from ultralytics) (3.10.0)
Requirement already satisfied: opencv-python>=4.6.0 in /usr/local/lib/python3.12/dist-packages (from ultralytics) (4.12.0.88)
Requirement already satisfied: pillow>=7.1.2 in /usr/local/lib/python3.12/dist-packages (from ultralytics) (11.3.0)
Requirement already satisfied: pyyaml>=5.3.1 in /usr/local/lib/python3.12/dist-packages (from ultralytics) (6.0.3)
Requirement already satisfied: requests>=2.23.0 in /usr/local/lib/python3.12/dist-packages (from ultralytics) (2.32.4)
Requirement already satisfied: scipy>=1.4.1 in /usr/local/lib/python3.12/dist-packages (from ultralytics) (1.16.2)
Requirement already satisfied: torch>=1.8.0 in /usr/local/lib/python3.12/dist-packages (from ultralytics) (2.8.0+cu126)
Requirement already satisfied: torchvision>=0.9.0 in /usr/local/lib/python3.12/dist-packages (from ultralytics) (0.23.0+cu126)
Requirement already satisfied: tsutil in /usr/local/lib/python3.12/dist-packages (from ultralytics) (5.9.5)
Requirement already satisfied: polars in /usr/local/lib/python3.12/dist-packages (from ultralytics) (1.25.2)
Collecting ultralytics-thop>=2.0.0 (from ultralytics)
  Downloading ultralytics_thop-2.0.17-py3-none-any.whl.metadata (14 kB)
Requirement already satisfied: contourpy>=1.0.1 in /usr/local/lib/python3.12/dist-packages (from matplotlib>=3.3.0->ultralytics) (1.3.3)
Requirement already satisfied: cycler>=0.10 in /usr/local/lib/python3.12/dist-packages (from matplotlib>=3.3.0->ultralytics) (0.12.1)
Requirement already satisfied: fonttools>=4.22.0 in /usr/local/lib/python3.12/dist-packages (from matplotlib>=3.3.0->ultralytics) (4.60.1)
Requirement already satisfied: kiwisolver>=1.3.1 in /usr/local/lib/python3.12/dist-packages (from matplotlib>=3.3.0->ultralytics) (1.4.9)
Requirement already satisfied: packaging>=20.0 in /usr/local/lib/python3.12/dist-packages (from matplotlib>=3.3.0->ultralytics) (25.0)
Requirement already satisfied: pyparsing>=2.3.1 in /usr/local/lib/python3.12/dist-packages (from matplotlib>=3.3.0->ultralytics) (3.2.5)
Requirement already satisfied: python-dateutil>=2.7 in /usr/local/lib/python3.12/dist-packages (from matplotlib>=3.3.0->ultralytics) (2.9.0.post0)
Requirement already satisfied: charset-normalizer<4, >=2 in /usr/local/lib/python3.12/dist-packages (from requests>=2.23.0->ultralytics) (3.4.4)
Requirement already satisfied: idna<4, >=2.5 in /usr/local/lib/python3.12/dist-packages (from requests>=2.23.0->ultralytics) (3.11)
Requirement already satisfied: urllib3<3, >=1.21.1 in /usr/local/lib/python3.12/dist-packages (from requests>=2.23.0->ultralytics) (2.5.0)
Requirement already satisfied: certifi>=2017.4.17 in /usr/local/lib/python3.12/dist-packages (from requests>=2.23.0->ultralytics) (2025.10.5)
Requirement already satisfied: filelock in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (3.20.0)
Requirement already satisfied: typing-extensions>=4.10.0 in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (4.15.0)
Requirement already satisfied: setuptools in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (75.2.0)
Requirement already satisfied: sympy>=1.13.3 in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (1.13.3)
Requirement already satisfied: networkx in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (3.5)
Requirement already satisfied: Jinja2 in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (3.1.6)
Requirement already satisfied: fsspec in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (2025.3.0)
Requirement already satisfied: cuda-cupti-nvrtc-cu12==12.6.77 in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (12.6.77)
Requirement already satisfied: cuda-cupti-runtime-cu12==12.6.77 in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (12.6.77)
Requirement already satisfied: cuda-cupti-cu12==12.6.80 in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (12.6.80)
Requirement already satisfied: cuda-cudnn-cu12==9.10.2.21 in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (9.10.2.21)
Requirement already satisfied: cuda-cublas-cu12==12.6.4.1 in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (12.6.4.1)
Requirement already satisfied: cuda-cufft-cu12==11.3.0.4 in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (11.3.0.4)
Requirement already satisfied: cuda-curand-cu12==10.3.7.77 in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (10.3.7.77)
Requirement already satisfied: cuda-cusolver-cu12==11.7.1.2 in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (11.7.1.2)
Requirement already satisfied: cuda-cusparse-cu12==12.5.4.2 in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (12.5.4.2)
Requirement already satisfied: cuda-cusparselt-cu12==0.7.1 in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (0.7.1)
Requirement already satisfied: nvcc-nccl-cu12==2.27.3 in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (2.27.3)
Requirement already satisfied: nvcc-nvtx-cu12==12.6.77 in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (12.6.77)
Requirement already satisfied: nvcc-nvjitlink-cu12==12.6.85 in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (12.6.85)
Requirement already satisfied: nvcc-cuda-file-cu12==1.11.6 in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (1.11.6)
Requirement already satisfied: triton==4.0 in /usr/local/lib/python3.12/dist-packages (from torch>=1.8.0->ultralytics) (3.4.0)
Requirement already satisfied: six>=1.5 in /usr/local/lib/python3.12/dist-packages (from python-dateutil>=2.7->matplotlib>=3.3.0->ultralytics) (1.17.0)
Requirement already satisfied: mpmath<1.4, >=1.1.0 in /usr/local/lib/python3.12/dist-packages (from sympy>=1.13.3->torch>=1.8.0->ultralytics) (1.3.0)
Requirement already satisfied: MarkupSafe>=2.0 in /usr/local/lib/python3.12/dist-packages (from Jinja2->torch>=1.8.0->ultralytics) (3.0.3)
Downloading ultralytics-8.3.221-py3-none-any.whl (1.1 MB)
1.1/1.1 MB 17.9 MB/s eta 0:00:00
Downloading ultralytics_thop-2.0.17-py3-none-any.whl (28 kB)
Installing collected packages: ultralytics-thop, ultralytics
Successfully installed ultralytics-8.3.221 ultralytics-thop-2.0.17
```

```
from ultralytics import YOLO

# Cargar el modelo
model = YOLO("yolo11n.pt")

# Entrenar el modelo
results = model.train(data="/content/datasets/data.yaml",
                      epochs=50, # Número de iteraciones
                      imgsz=640, # Tamaño de las imágenes (máxima dimensión)
                      plots=True, # Guardar gráficos de entrenamiento
                      )
```

```
... Creating new Ultralytics settings v0.0.6 file
View Ultralytics settings with 'yolo settings' or at '/root/.config/ultralytics/settings.json'
Update settings with 'yolo settings key=value', i.e. 'yolo settings runs_dir=path/to/dir'. For help see https://docs.ultralytics.com/quickstart/#ultralytics-settings.
Downloading https://github.com/ultralytics/assets/releases/download/v0.1.0/yolo11n.pt: 100% [#####] 5.35H/5.35H [00:00:00.00, 58.2MB/s]
Ultralytics 8.3.177 of python-3.11.13 torch-2.6.0+cu126 CPU (Intel Xeon 2.400GHz)
engine/trainer: agnostic, nms=False, amp=True, augment=False, auto_augment=randaugmix, batch=16, bgr=0, box=7.5, cache=False, cfg=None, classes=None, close_mosaic=10, cls=0.5, conf=None, copy_paste=0, copy_paste_mode=flip, cos_lr=False
Downloading https://ultralytics.com/assets/arial.ttf to '/root/.config/ultralytics/arial.ttf': 100% [#####] 755K/755K [00:00:00.00, 10.7MB/s]overriding model.yaml nc=80 with nc=3

   from  n  params  module  arguments
   --  --  --  --  --
0  -1  1  464  ultralytics.nn.modules.conv.Conv  [5, 16, 3, 2]
1  -1  1  4672  ultralytics.nn.modules.conv.Conv  [16, 32, 3, 2]
2  -1  1  6640  ultralytics.nn.modules.block.C3k2  [32, 64, 1, False, 0.25]
3  -1  1  5692  ultralytics.nn.modules.conv.Conv  [64, 64, 3, 2]
4  -1  1  26880  ultralytics.nn.modules.block.C3k2  [64, 128, 1, False, 0.25]
5  -1  1  147712  ultralytics.nn.modules.conv.Conv  [128, 128, 3, 2]
6  -1  1  37040  ultralytics.nn.modules.block.C3k2  [128, 128, 1, True]
7  -1  1  295424  ultralytics.nn.modules.conv.Conv  [128, 256, 3, 2]
8  -1  1  346112  ultralytics.nn.modules.block.C3k2  [256, 256, 1, True]
9  -1  1  164680  ultralytics.nn.modules.block.SPPF  [256, 256, 5]
10  -1  1  249728  ultralytics.nn.modules.block.C2PSA  [256, 256, 1]
11  -1  1  0  torch.nn.modules.upsampling.Upsample  [None, 2, 'nearest']
12  [-1, 6]  1  0  ultralytics.nn.modules.conv.Concat  [1]
13  -1  1  111296  ultralytics.nn.modules.block.C3k2  [384, 128, 1, False]
14  -1  1  0  torch.nn.modules.upsampling.Upsample  [None, 2, 'nearest']
15  [-1, 6]  1  0  ultralytics.nn.modules.conv.Concat  [1]
16  -1  1  32096  ultralytics.nn.modules.block.C3k2  [256, 64, 1, False]
17  -1  1  36892  ultralytics.nn.modules.conv.Conv  [64, 64, 3, 2]
18  [-1, 13]  1  0  ultralytics.nn.modules.conv.Concat  [1]
19  -1  1  86720  ultralytics.nn.modules.block.C3k2  [192, 128, 1, False]
20  -1  1  147712  ultralytics.nn.modules.conv.Conv  [128, 128, 3, 2]
21  [-1, 10]  1  0  ultralytics.nn.modules.conv.Concat  [1]
22  -1  1  378880  ultralytics.nn.modules.block.C3k2  [384, 256, 1, True]
23  [16, 19, 22]  1  451257  ultralytics.nn.modules.head.Detect  [5, [64, 128, 256]]

YOLO11n summary: 181 layers, 2,590,425 parameters, 2,590,409 gradients, 6.4 GFLOPs

Transferred 448/450 items from pretrained weights
Freezing layer 'model.23.dfl.conv.weight'
train: Fast image access (img: 0.070 s/m, read: 1551.05500 s/MB/s, size: 3540.1 KB)
train: Scanning /content/datasets/labels/train... 1720 Images, 6 backgrounds, 0 corrupt: 100% [#####] 1720/1720 [00:01:00.00, 1367.491t/s]train: New cache created: /content/datasets/labels/train.cache
val: Fast image access (img: 0.070 s/m, read: 2289.321401 s/MB/s, size: 5044.8 KB)
val: Scanning /content/datasets/labels/val... 430 Images, 2 backgrounds, 0 corrupt: 100% [#####] 430/430 [00:00:00.00, 1549.631t/s]val: New cache created: /content/datasets/labels/val.cache
```

```

*** Flushing labels to runs/detect/train/labels.jpg...
optimizer: 'optimizer=auto' found, ignoring 'lr=0.01' and 'momentum=0.937' and determining best 'optimizer', 'lr' and 'momentum' automatically...
optimizer: Adam(lr=0.001429, momentum=0.9) with parameter groups 81 weight(decay=0.0), 88 weight(decay=0.0005), 87 bias(decay=0.0)
Image sizes 640 train, 640 val
Using 0 dataloader workers
Logging results to runs/detect/train
Starting training for 20 epochs...

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
1/20 0G 1.424 2.519 1.452 15 640: 100% ██████████ 100/100 [07:28:00:00, 4.15s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:17:00:00, 4.11s/it] all 430 555 0.513 0.517 0.562 0.304

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
2/20 0G 1.434 1.819 1.444 22 640: 100% ██████████ 100/100 [07:34:00:00, 4.21s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:18:00:00, 3.69s/it] all 430 555 0.543 0.593 0.593 0.327

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
3/20 0G 1.487 1.647 1.465 15 640: 100% ██████████ 100/100 [07:33:00:00, 4.19s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:18:00:00, 3.54s/it] all 430 555 0.576 0.576 0.6 0.313

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
4/20 0G 1.436 1.467 1.442 20 640: 100% ██████████ 100/100 [07:40:00:00, 4.26s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:19:00:00, 4.23s/it] all 430 555 0.721 0.526 0.604 0.332

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
5/20 0G 1.445 1.265 1.422 25 640: 100% ██████████ 100/100 [07:42:00:00, 4.28s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:19:00:00, 3.41s/it] all 430 555 0.764 0.639 0.735 0.424

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
6/20 0G 1.375 1.176 1.392 21 640: 100% ██████████ 100/100 [07:45:00:00, 4.31s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:19:00:00, 3.85s/it] all 430 555 0.795 0.736 0.813 0.467

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
7/20 0G 1.363 1.103 1.387 35 640: 100% ██████████ 100/100 [07:46:00:00, 4.32s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:19:00:00, 3.26s/it] all 430 555 0.841 0.78 0.862 0.508

***

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
8/20 0G 1.321 1.061 1.352 19 640: 100% ██████████ 100/100 [07:38:00:00, 4.25s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:18:00:00, 3.26s/it] all 430 555 0.829 0.826 0.886 0.567

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
9/20 0G 1.283 0.9751 1.226 29 640: 100% ██████████ 100/100 [07:47:00:00, 4.33s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:18:00:00, 3.48s/it] all 430 555 0.88 0.842 0.91 0.59

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
10/20 0G 1.275 0.9505 1.319 23 640: 100% ██████████ 100/100 [07:45:00:00, 4.31s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:18:00:00, 3.44s/it] all 430 555 0.921 0.87 0.932 0.599

Closing dataloader mosaic

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
11/20 0G 1.195 0.8159 1.319 8 640: 100% ██████████ 100/100 [07:28:00:00, 4.16s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:18:00:00, 3.71s/it] all 430 555 0.886 0.906 0.93 0.604

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
12/20 0G 1.187 0.7638 1.316 10 640: 100% ██████████ 100/100 [07:17:00:00, 4.24s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:18:00:00, 3.51s/it] all 430 555 0.9 0.932 0.95 0.645

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
13/20 0G 1.134 0.7007 1.269 10 640: 100% ██████████ 100/100 [07:37:00:00, 4.23s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:18:00:00, 3.58s/it] all 430 555 0.910 0.894 0.940 0.648

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
14/20 0G 1.116 0.6677 1.25 10 640: 100% ██████████ 100/100 [07:50:00:00, 4.36s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:18:00:00, 3.70s/it] all 430 555 0.94 0.943 0.962 0.664

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
15/20 0G 1.082 0.635 1.231 8 640: 100% ██████████ 100/100 [07:50:00:00, 4.36s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:18:00:00, 3.58s/it] all 430 555 0.941 0.936 0.97 0.677

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
16/20 0G 1.075 0.6014 1.22 8 640: 100% ██████████ 100/100 [07:45:00:00, 4.31s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:18:00:00, 3.75s/it] all 430 555 0.939 0.932 0.969 0.686

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
17/20 0G 1.043 0.5757 1.201 12 640: 100% ██████████ 100/100 [07:51:00:00, 4.38s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:18:00:00, 3.62s/it] all 430 555 0.923 0.921 0.97 0.701

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
18/20 0G 1.028 0.554 1.193 10 640: 100% ██████████ 100/100 [07:56:00:00, 4.41s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:18:00:00, 3.36s/it] all 430 555 0.939 0.944 0.975 0.704

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
19/20 0G 1.009 0.5329 1.179 8 640: 100% ██████████ 100/100 [07:38:00:00, 4.17s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:18:00:00, 3.53s/it] all 430 555 0.95 0.933 0.974 0.709

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
20/20 0G 0.994 0.5104 1.176 12 640: 100% ██████████ 100/100 [07:34:00:00, 4.21s/it]
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:18:00:00, 3.67s/it] all 430 555 0.952 0.959 0.977 0.718

20 epochs completed in 2.846 hours.
Optimizer stripped from runs/detect/train/weights/last.pt, 5.5MB
Optimizer stripped from runs/detect/train/weights/best.pt, 5.5MB

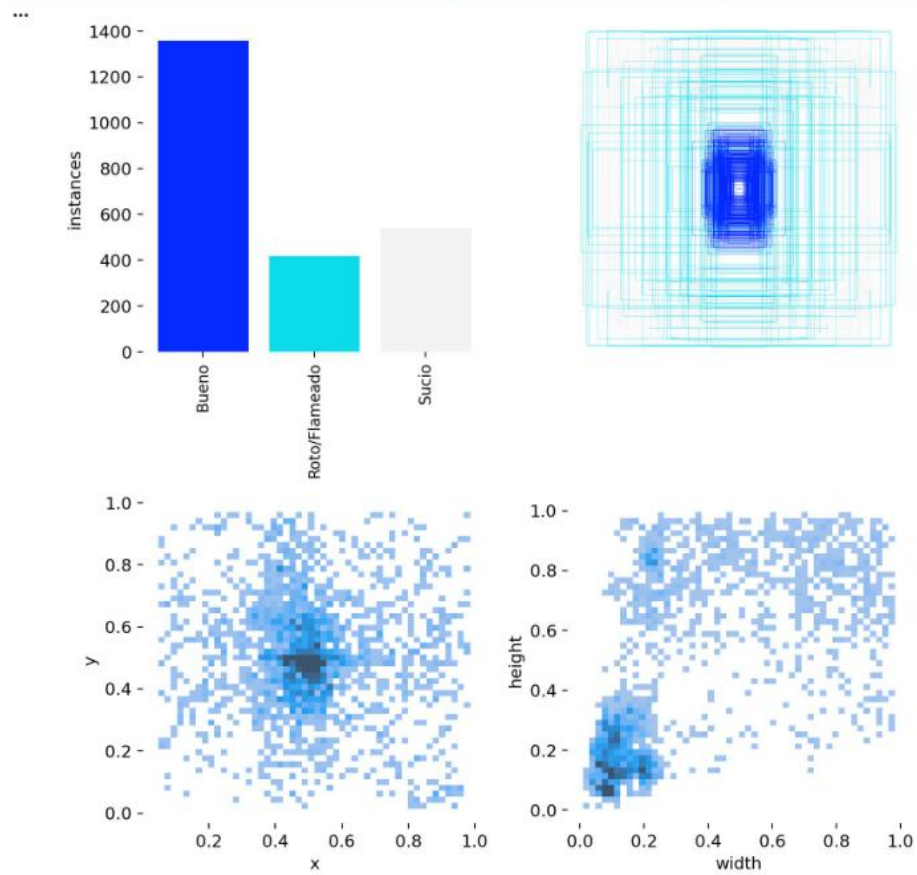
Validating runs/detect/train/weights/best.pt...
Ultralytics 8.1.137 on Python-3.11.13 torch-2.6.0-cpu CPU (Intel Xeon 2.80GHz)
YOLO11n summary (fused): 100 layers, 2,582,737 parameters, 0 gradients, 6.3 GFLOPs
Class Images Instances Box(P) R mAP50 mAP50-95: 100% ██████████ 14/14 [00:14:00:00, 3.34s/it]
all 430 555 0.952 0.958 0.977 0.710
Bueno 194 306 0.958 0.976 0.988 0.651
Roto/Flameado 101 107 0.908 0.944 0.953 0.717
Sucio 133 142 0.89 0.958 0.991 0.785
Speed: 1.2ms preprocess, 61.0ms inference, 0.0ms loss, 1.0ms postprocess per image
Results saved to runs/detect/train

```

## Modelo yolo1 In.pt

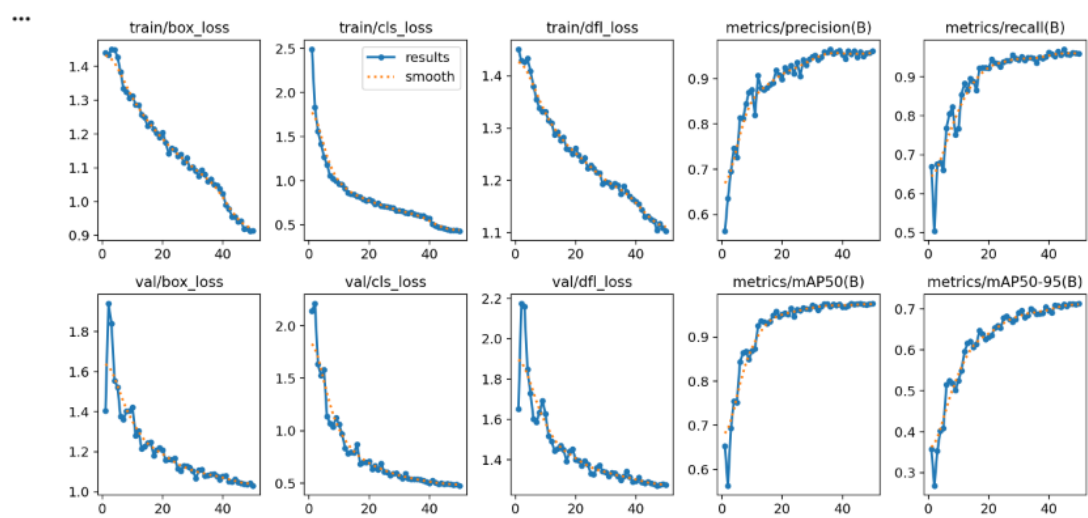
```
from IPython.display import Image as IPyImage
```

```
IPyImage(filename='/content/drive/MyDrive/Tesis Aisladores/runs/detect/train3/labels.jpg', width=800)
```




```
from IPython.display import Image as IPyImage
```

```
IPyImage(filename='/content/drive/MyDrive/Tesis Aisladores/runs/detect/train3/results.png', width=800)
```



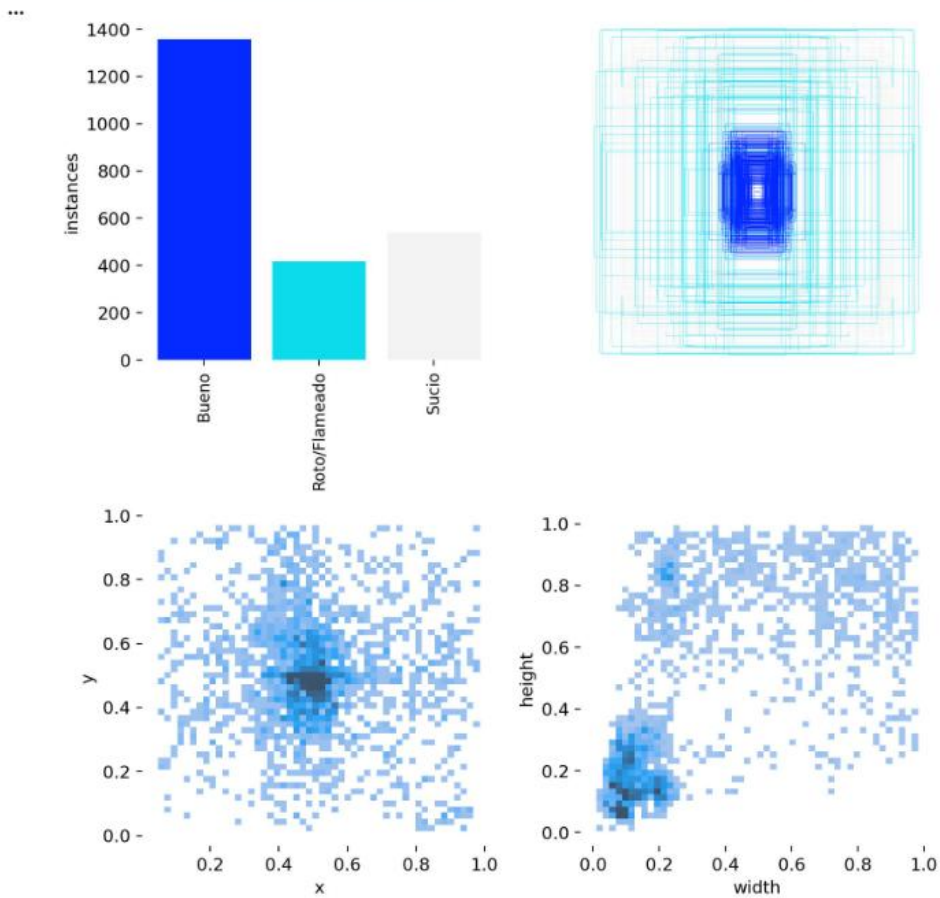
```
IPyImage(filename='/content/drive/MyDrive/Tesis Aisladores/runs/detect/train3/confusion_matrix.png', width=900)
```



## Modelo yolo11s.pt

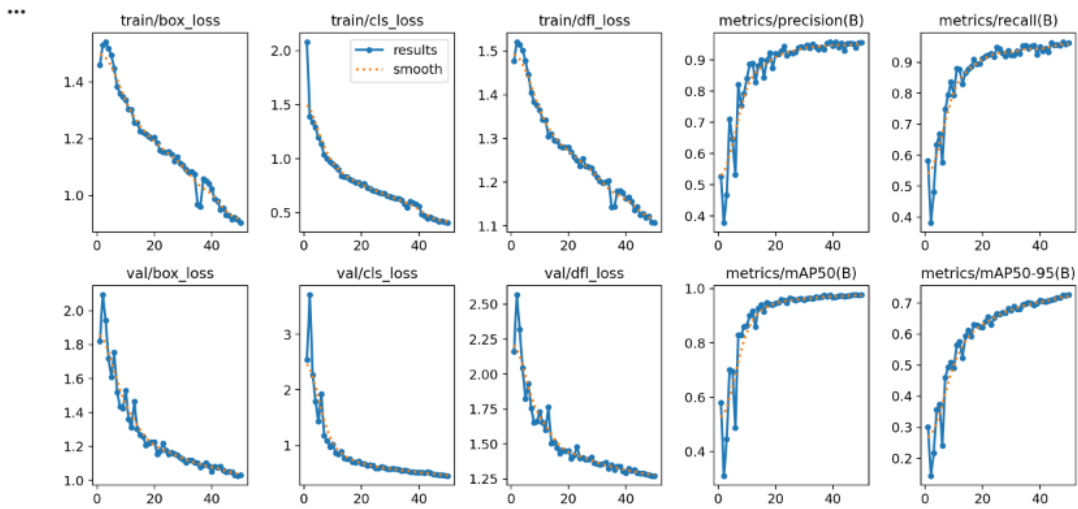
```
from IPython.display import Image as IPyImage
```

```
IPyImage(filename='/content/drive/MyDrive/Tesis Aisladores/runs/detect/train4/labels.jpg', width=800)
```




```
from IPython.display import Image as IPyImage
```

```
IPyImage(filename='/content/drive/MyDrive/Tesis Aisladores/runs/detect/train4/results.png', width=800)
```



```
IPyImage(filename='/content/drive/MyDrive/Tesis Aisladores/runs/detect/train3/confusion_matrix.png', width=900)
```



Fuente: Elaboración propia

# Anexo 20

## Generación de predicciones con el modelo

```
from ultralytics import YOLO
model = YOLO('/content/drive/MyDrive/Tesis Aisladores/runs/detect/train4/weights/best.pt')

... Creating new Ultralytics Settings v0.0.6 file
View Ultralytics Settings with 'yolo settings' or at '/root/.config/Ultralytics/settings.json'
Update Settings with 'yolo settings key=value', i.e. 'yolo settings runs_dir=path/to/dir'. For help see https://docs.ultralytics.com/quickstart/#ultralytics-settings.

preds = model('/content/drive/MyDrive/Tesis Aisladores/datasets/images/val')

...
image 1/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/00cf2e17-asb_21.jpg: 576x640 1 Bueno, 106.3ms
image 2/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/023b54c6-asd_175.jpg: 448x640 1 Roto/Flameado, 117.9ms
image 3/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/02a64e13-asb_444.jpg: 576x640 1 Bueno, 104.5ms
image 4/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/03a4fd84-asd_310.jpg: 448x640 1 Roto/Flameado, 171.4ms
image 5/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/03f59328-asb_297.jpg: 576x640 1 Bueno, 89.4ms
image 6/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/0400cda7-asd_375.jpg: 416x640 1 Roto/Flameado, 264.9ms
image 7/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/0456c49c-asb_853.jpg: 576x640 1 Bueno, 116.1ms
image 8/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/04991ee5-ass_157.jpg: 640x640 1 Sucio, 189.3ms
image 9/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/04a799f1-asd_466.jpg: 640x640 1 Roto/Flameado, 186.7ms
image 10/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/051a26c4-ass_389.jpg: 640x640 1 Sucio, 183.1ms
image 11/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/051c6516-assa_016.jpg: 640x640 1 Sucio, 186.4ms
image 12/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/0525206d-asb_580.jpg: 576x640 2 Buenos, 101.8ms
image 13/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/05b500d3-asd_073.jpg: 448x640 1 Roto/Flameado, 168.9ms
image 14/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/05ab5df1-asb_10.jpg: 576x640 3 Buenos, 127.7ms
image 15/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/05d3064c-asb_834.jpg: 576x640 1 Bueno, 96.2ms
image 16/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/05ef12ac-asb_535.jpg: 576x640 1 Bueno, 90.6ms
image 17/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/082cc4fc-assa_083.jpg: 640x640 1 Sucio, 182.7ms
image 18/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/085075fb-asd_102.jpg: 448x640 1 Roto/Flameado, 116.5ms
image 19/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/09240878-asb_783.jpg: 576x640 4 Buenos, 124.4ms
image 20/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/0974515b-asd_180.jpg: 448x640 1 Roto/Flameado, 116.5ms
image 21/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/097d94f6-ass_264.jpg: 640x640 1 Sucio, 132.4ms
image 22/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/0985cecd-ass_346.jpg: 640x640 1 Sucio, 131.7ms
image 23/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/09f16ea5-asd_489.jpg: 640x640 1 Roto/Flameado, 185.8ms
image 24/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/09f5b36b-asb_124.jpg: 576x640 2 Buenos, 84.0ms
image 25/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/0a375541-asb_508.jpg: 576x640 1 Bueno, 127.3ms
image 26/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/0a7bd67a-asb_586.jpg: 576x640 2 Buenos, 131.4ms
image 27/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/0ab83d50-asd_496.jpg: 640x448 1 Roto/Flameado, 176.7ms
image 28/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/0ae7f993-asd_041.jpg: 640x640 1 Roto/Flameado, 189.9ms
image 29/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/0b1f8d5b-asb_107.jpg: 576x640 1 Bueno, 120.4ms
image 30/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/0c4d93a1-asb_351.jpg: 576x640 1 Bueno, 130.6ms
image 31/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/0ee6549d-asb_227.jpg: 576x640 1 Bueno, 109.0ms
image 32/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/0f9e87a2-asd_443.jpg: 640x640 1 Roto/Flameado, 190.3ms
image 33/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/138ae926-ass_039.jpg: 640x640 1 Sucio, 188.6ms
...
image 34/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/13b282db-asd_016.jpg: 640x640 1 Roto/Flameado, 190.3ms
image 35/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/142cde87-asd_173.jpg: 448x640 1 Roto/Flameado, 175.8ms
image 36/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/14fe1ded-ass_050.jpg: 640x640 1 Sucio, 189.5ms
image 37/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1633cffe-asb_267.jpg: 576x640 1 Bueno, 115.8ms
image 38/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/16d4395d-ass_070.jpg: 640x640 1 Sucio, 187.9ms
image 39/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/16f43c76-asb_945.jpg: 576x640 1 Bueno, 76.1ms
image 40/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/17c8ad32-ass_052.jpg: 640x640 1 Sucio, 133.2ms
image 41/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/17cfa638-asb_890.jpg: 576x640 1 Bueno, 134.8ms
image 42/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1872266f-asb_147.jpg: 576x640 2 Buenos, 123.2ms
image 43/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/191e99fe-ass_294.jpg: 640x640 1 Sucio, 185.4ms
image 44/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1a35282c-ass_452.jpg: 640x640 1 Sucio, 186.5ms
image 45/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1a3baf64-asb_37.jpg: 576x640 2 Buenos, 106.3ms
image 46/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1a76bb6a-ass_195.jpg: 640x640 2 Sucios, 132.2ms
image 47/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1b103af0-asb_809.jpg: 576x640 2 Buenos, 73.2ms
image 48/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1b2d757e-asd_048.jpg: 448x640 1 Roto/Flameado, 116.6ms
image 49/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1b50f8d3-asb_378.jpg: 576x640 1 Bueno, 114.1ms
image 50/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1b86c1ca-asb_252.jpg: 576x640 1 Bueno, 73.9ms
image 51/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1b997bd3-asb_792.jpg: 576x640 2 Buenos, 122.1ms
image 52/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1c2488b4-ass_025.jpg: 640x640 1 Sucio, 188.2ms
image 53/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1c791c68-ass_430.jpg: 640x640 1 Sucio, 185.8ms
image 54/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1cc7c4a1-asb_317.jpg: 576x640 1 Bueno, 117.0ms
image 55/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1d270f0f-asb_798.jpg: 576x640 2 Buenos, 100.9ms
image 56/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1d6f2a2f-ass_263.jpg: 640x640 1 Sucio, 185.8ms
image 57/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1d7e58af-ass_047.jpg: 640x640 1 Sucio, 186.2ms
image 58/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1e108af6-asb_872.jpg: 576x640 1 Bueno, 117.6ms
image 59/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1f92436e-asd_165.jpg: 448x640 1 Roto/Flameado, 169.6ms
image 60/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/1fda767d-asb_940.jpg: 576x640 1 Bueno, 113.2ms
image 61/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/214c5e0c-ass_132.jpg: 640x640 1 Sucio, 186.9ms
image 62/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/216fc6ff-assa_161.jpg: 640x640 1 Sucio, 187.8ms
image 63/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/230256a2-asb_676.jpg: 576x640 7 Buenos, 79.9ms
image 64/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/2398e690-asd_011.jpg: 640x640 1 Roto/Flameado, 132.3ms
image 65/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/248b4a75-asb_893.jpg: 576x640 1 Bueno, 132.3ms
image 66/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/249b8eb7-asd_382.jpg: 544x640 1 Roto/Flameado, 227.1ms
image 67/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/249d20ca-ass_085.jpg: 640x640 1 Sucio, 133.2ms
...
image 68/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/255bcb96-asd_364.jpg: 640x320 1 Roto/Flameado, 1 Sucio, 146.6ms
image 69/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/25c78af7-assa_091.jpg: 640x640 1 Sucio, 131.8ms
image 70/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/25f3dcde-asb_188.jpg: 576x640 1 Bueno, 122.0ms
image 71/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/265bf257-asd_060.jpg: 448x640 1 Roto/Flameado, 117.8ms
image 72/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/26da4db8-ass_438.jpg: 640x640 1 Sucio, 134.1ms
image 73/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/27eaa1ac-asb_257.jpg: 576x640 1 Bueno, 122.7ms
image 74/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/2878e694-asb_41.jpg: 576x640 1 Bueno, 126.6ms
image 75/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/28b045c9-asb_60.jpg: 576x640 1 Bueno, 73.4ms
image 76/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/28b68a70-asb_39.jpg: 576x640 2 Buenos, 110.6ms
image 77/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/29310f3b-asb_422.jpg: 576x640 1 Bueno, 125.5ms
image 78/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/299855c3-asb_417.jpg: 576x640 1 Bueno, 77.3ms
image 79/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/2ac7a84a-asb_713.jpg: 576x640 3 Buenos, 133.1ms
image 80/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/2b0edf9d-asd_366.jpg: 640x640 1 Roto/Flameado, 186.9ms
image 81/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/2b55f54f-assa_082.jpg: 640x640 1 Sucio, 186.8ms
image 82/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/2d9b7f3a-asb_498.jpg: 576x640 1 Bueno, 121.8ms
image 83/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/2ee4a3a1-ass_231.jpg: 640x640 1 Sucio, 188.2ms
image 84/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/2f023161-asd_400.jpg: 640x640 1 Roto/Flameado, 184.4ms
image 85/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/2f8df083-assa_020.jpg: 640x640 2 Sucios, 189.7ms
```

```

... image 86/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/2feb8c01-ass_227.jpg: 640x640 1 Sucio, 189.5ms
image 87/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/30124831-asd_119.jpg: 448x640 1 Roto/Flameado, 117.1ms
image 88/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/301a0319-asb_944.jpg: 576x640 1 Bueno, 124.5ms
image 89/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/31dcabf3-asb_30.jpg: 576x640 2 Buenos, 126.0ms
image 90/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/3245d95a-ass_099.jpg: 640x640 1 Sucio, 186.3ms
image 91/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/33e1f5c3-asb_483.jpg: 576x640 1 Bueno, 77.0ms
image 92/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/33ea2ebf-asb_376.jpg: 576x640 1 Bueno, 127.1ms
image 93/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/351f5566-ass_292.jpg: 640x640 1 Sucio, 195.8ms
image 94/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/358dc5a3-asb_364.jpg: 576x640 2 Buenos, 114.8ms
image 95/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/367f431b-asd_129.jpg: 448x640 1 Roto/Flameado, 176.5ms
image 96/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/36929dff-asb_520.jpg: 576x640 1 Bueno, 122.0ms
image 97/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/36fc773d-asb_93.jpg: 576x640 1 Bueno, 91.0ms
image 98/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/375948fa-assa_041.jpg: 640x640 1 Sucio, 186.4ms
image 99/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/394ae9fd-ass_441.jpg: 640x640 2 Sucios, 188.6ms
image 100/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/3967f091-asb_954.jpg: 576x640 1 Bueno, 93.4ms
image 101/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/39f55d6d-asd_181.jpg: 448x640 1 Roto/Flameado, 171.5ms
image 102/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/3a4c5166-asb_109.jpg: 576x640 1 Bueno, 119.3ms
image 103/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/3a84c1a8-ass_466.jpg: 640x640 1 Sucio, 131.6ms
image 104/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/3b1c5fbb-ass_162.jpg: 640x640 1 Sucio, 189.4ms
image 105/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/3b89ddce-asb_464.jpg: 576x640 1 Bueno, 126.4ms
image 106/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/3bf6d2a5-asb_686.jpg: 576x640 2 Buenos, 97.1ms
image 107/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/3c2a309e-asb_977.jpg: 576x640 1 Bueno, 126.0ms
image 108/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/3c99ce6c-asb_637.jpg: 576x640 2 Buenos, 118.4ms
image 109/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/3e51f300-asd_321.jpg: 448x640 1 Roto/Flameado, 170.0ms
image 110/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/3ea076d9-asd_267.jpg: 448x640 1 Roto/Flameado, 118.0ms
image 111/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/3eccc0ca-ass_030.jpg: 640x640 1 Sucio, 132.0ms
image 112/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/3f10dc43-ass_088.jpg: 640x640 1 Sucio, 183.9ms
image 113/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/3f998d9c-assa_104.jpg: 640x640 1 Sucio, 187.0ms
image 114/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/3f9ddaf3-asd_282.jpg: 448x640 1 Roto/Flameado, 171.4ms
image 115/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/3fb970b2-asb_356.jpg: 576x640 1 Bueno, 127.8ms
image 116/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/3felbale-asb_956.jpg: 576x640 1 Bueno, 76.0ms
image 117/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/401159d5-asb_941.jpg: 576x640 1 Bueno, 125.3ms
image 118/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/4116f6b3-asb_524.jpg: 576x640 1 Bueno, 122.5ms
image 119/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/4138179b-ass_270.jpg: 640x640 1 Sucio, 186.2ms
image 120/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/416af2ab-asd_224.jpg: 448x640 1 Roto/Flameado, 170.5ms
image 121/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/41bba702-assa_063.jpg: 640x640 1 Sucio, 188.5ms
... image 122/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/41d0d588-asd_037.jpg: 448x640 2 Roto/Flameados, 119.8ms
image 123/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/42d54890-asd_113.jpg: 448x640 1 Roto/Flameado, 170.7ms
image 124/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/441ac783-ass_296.jpg: 640x640 1 Sucio, 185.7ms
image 125/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/44d9c75b-asb_623.jpg: 576x640 4 Buenos, 119.8ms
image 126/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/44fd0c0c-asb_402.jpg: 576x640 1 Bueno, 75.4ms
image 127/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/453a456c-asb_703.jpg: 576x640 6 Buenos, 130.3ms
image 128/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/45461f80-ass_143.jpg: 640x640 1 Sucio, 184.8ms
image 129/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/45e8b985-asb_814.jpg: 576x640 2 Buenos, 125.5ms
image 130/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/46cf61f5-asd_222.jpg: 448x640 1 Roto/Flameado, 116.6ms
image 131/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/481b7b25-asb_568.jpg: 576x640 2 Buenos, 128.3ms
image 132/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/48d4f121-asd_047.jpg: 640x640 1 Roto/Flameado, 191.8ms
image 133/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/4a9b9ca7-assa_124.jpg: 640x640 2 Sucios, 185.6ms
image 134/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/4ad8e512-asb_540.jpg: 576x640 2 Buenos, 76.4ms
image 135/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/4b5e1f25-asb_390.jpg: 576x640 1 Bueno, 133.2ms
image 136/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/4c0a2de3-asd_276.jpg: 448x640 1 Roto/Flameado, 173.6ms
image 137/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/4c40f864-asb_112.jpg: 576x640 1 Bueno, 129.9ms
image 138/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/4c689975-asb_746.jpg: 576x640 3 Buenos, 126.3ms
image 139/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/4d023c83-asb_388.jpg: 576x640 1 Bueno, 127.0ms
image 140/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/4d3d16d3-ass_300.jpg: 640x640 1 Sucio, 187.8ms
image 141/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/4d49c9d-asb_064.jpg: 640x640 1 Roto/Flameado, 187.2ms
image 142/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/4d54d16b-asb_315.jpg: 576x640 1 Bueno, 104.1ms
image 143/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/4daabc2d-ass_421.jpg: 640x640 1 Sucio, 187.7ms
image 144/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/4efc9fbc-asb_765.jpg: 576x640 1 Bueno, 136.1ms
image 145/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/51696435-asd_140.jpg: 448x640 1 Roto/Flameado, 121.6ms
image 146/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/51e9f058-asd_198.jpg: 448x640 1 Roto/Flameado, 116.0ms
image 147/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/523e59be-asb_420.jpg: 576x640 1 Bueno, 88.2ms
image 148/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/528f0092-asb_175.jpg: 576x640 2 Buenos, 128.5ms
image 149/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/53f2f46b-ass_213.jpg: 640x640 2 Sucios, 182.8ms
image 150/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/542c96a6-ass_013.jpg: 640x640 1 Sucio, 131.9ms
image 151/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/55694c11-asb_393.jpg: 576x640 1 Bueno, 136.9ms
image 152/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/55e8c5b3-asd_444.jpg: 640x640 1 Roto/Flameado, 191.6ms
image 153/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/5613e48a-asb_964.jpg: 576x640 1 Bueno, 132.8ms
image 154/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/5639bcb2-ass_352.jpg: 640x640 1 Sucio, 193.4ms
image 155/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/56c1ab34-assa_093.jpg: 640x640 1 Sucio, 186.5ms
image 156/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/56f6de1f-ass_137.jpg: 640x640 1 Sucio, 189.1ms
image 157/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/576d6938-assa_076.jpg: 640x640 1 Sucio, 187.2ms
image 158/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/584a0f47-ass_192.jpg: 640x640 1 Sucio, 185.4ms
... image 159/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/5898f344-ass_311.jpg: 640x640 1 Sucio, 184.3ms
image 160/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/5c8ab026-asb_53.jpg: 576x640 1 Bueno, 121.0ms
image 161/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/5f02cf6d-asb_895.jpg: 576x640 2 Buenos, 86.4ms
image 162/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/60a51e01-ass_226.jpg: 640x640 1 Sucio, 186.1ms
image 163/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/61b891cd-asd_458.jpg: 640x640 1 Roto/Flameado, 185.3ms
image 164/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/6202cdeb5-ass_237.jpg: 640x640 1 Sucio, 189.2ms
image 165/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/620520af-assa_116.jpg: 640x640 1 Sucio, 184.0ms
image 166/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/62e279d3-asd_243.jpg: 448x640 1 Roto/Flameado, 117.1ms
image 167/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/641d78fc-assa_121.jpg: 640x640 1 Sucio, 133.9ms
image 168/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/649886a7-asb_912.jpg: 576x640 2 Buenos, 128.2ms
image 169/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/65224b59-asd_069.jpg: 448x640 2 Roto/Flameados, 175.4ms
image 170/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/65bc3522-asb_52.jpg: 576x640 1 Bueno, 125.3ms
image 171/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/65c88b86-asd_111.jpg: 448x640 1 Roto/Flameado, 175.3ms
image 172/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/65e92fcd-ass_458.jpg: 608x640 1 Sucio, 282.7ms
image 173/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/67691402-ass_167.jpg: 640x640 1 Sucio, 187.6ms
image 174/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/67c3e24b-asb_27.jpg: 576x640 1 Bueno, 126.3ms
image 175/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/681fac31-ass_223.jpg: 640x640 1 Sucio, 189.7ms
image 176/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/689c6c2a-asb_602.jpg: 576x640 4 Buenos, 92.7ms
image 177/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/69cdc573-ass_339.jpg: 640x640 1 Sucio, 131.0ms
image 178/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/6a3f15b6-assa_159.jpg: 640x640 1 Sucio, 189.1ms
image 179/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/6bead95a-ass_467.jpg: 640x640 1 Sucio, 186.2ms
image 180/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/6d81c2cc-asb_759.jpg: 576x640 1 Bueno, 103.4ms
image 181/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/6da9b4al-asb_916.jpg: 576x640 1 Bueno, 76.9ms
image 182/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/6dac20fa-asd_104.jpg: 448x640 1 Roto/Flameado, 116.3ms
image 183/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/6e1e6459-asd_236.jpg: 448x640 1 Roto/Flameado, 170.3ms
image 184/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/6f60d9d9-asb_312.jpg: 576x640 2 Buenos, 123.0ms
image 185/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/6fb2c09e-asb_516.jpg: 576x640 1 Bueno, 99.4ms
image 186/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/6fe964ee-asb_807.jpg: 576x640 3 Buenos, 92.9ms
image 187/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/702e84b9-asd_253.jpg: 448x640 1 Roto/Flameado, 171.2ms
image 188/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/712dff67-ass_295.jpg: 640x640 1 Sucio, 184.2ms

```

image 189/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/71b3c82d-assa\_144.jpg: 640x640 1 Sucio, 184.5ms  
 image 190/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/71c5d477-asd\_424.jpg: 640x640 1 Roto/Flameado, 131.6ms  
 ... image 191/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/7247d042-asb\_496.jpg: 576x640 1 Bueno, 126.0ms  
 image 192/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/72a5381f-asb\_177.jpg: 576x640 2 Buenos, 120.9ms  
 image 193/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/748e335c-asb\_791.jpg: 576x640 2 Buenos, 93.1ms  
 image 194/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/75322161-asd\_257.jpg: 448x640 1 Roto/Flameado, 171.2ms  
 image 195/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/75623369-assa\_098.jpg: 640x640 1 Sucio, 182.1ms  
 image 196/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/760b51b0-asd\_233.jpg: 448x640 1 Roto/Flameado, 120.3ms  
 image 197/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/763db407-assa\_125.jpg: 640x640 1 Sucio, 184.1ms  
 image 198/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/765fbaf2-ass\_005.jpg: 640x640 1 Sucio, 189.5ms  
 image 199/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/76e3539c-asd\_465.jpg: 640x640 1 Roto/Flameado, 187.0ms  
 image 200/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/76f8ba17-asd\_049.jpg: 448x640 1 Roto/Flameado, 115.5ms  
 image 201/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/7808ab03-ass\_432.jpg: 640x640 1 Sucio, 133.2ms  
 image 202/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/78fa0d8d-ass\_286.jpg: 640x640 1 Sucio, 132.4ms  
 image 203/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/79c2419c-asb\_622.jpg: 576x640 4 Buenos, 127.8ms  
 image 204/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/79d10906-asd\_137.jpg: 448x640 1 Roto/Flameado, 117.9ms  
 image 205/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/7aa022fb-asb\_700.jpg: 576x640 5 Buenos, 132.0ms  
 image 206/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/7aeadd7b8-asb\_937.jpg: 576x640 1 Bueno, 126.1ms  
 image 207/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/7b164b48-asd\_320.jpg: 448x640 1 Roto/Flameado, 117.6ms  
 image 208/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/7c1f6b4c-asb\_976.jpg: 576x640 1 Bueno, 139.0ms  
 image 209/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/7d13812e-ass\_463.jpg: 640x640 1 Roto/Flameado, 1 Sucio, 188.0ms  
 image 210/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/8263de91-asb\_910.jpg: 576x640 2 Buenos, 132.2ms  
 image 211/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/82fa3781-asd\_352.jpg: 448x640 1 Roto/Flameado, 118.2ms  
 image 212/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/837c8c8a-asd\_312.jpg: 448x640 1 Roto/Flameado, 118.8ms  
 image 213/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/83ed5995-asd\_404.jpg: 640x640 2 Roto/Flameados, 191.5ms  
 image 214/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/841beadc-asd\_109.jpg: 448x640 1 Roto/Flameado, 174.4ms  
 image 215/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/84d0e95-ass\_495.jpg: 640x640 1 Sucio, 191.3ms  
 image 216/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/85e5d274-asd\_365.jpg: 640x288 1 Roto/Flameado, 1 Sucio, 196.5ms  
 image 217/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/8639c5d4-asd\_211.jpg: 448x640 1 Roto/Flameado, 152.2ms  
 image 218/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/87b7a82a-ass\_385.jpg: 640x640 1 Sucio, 188.2ms  
 image 219/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/88ab8fa2-ass\_253.jpg: 640x640 1 Sucio, 187.5ms  
 image 220/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/88d4d136-asd\_200.jpg: 448x640 1 Roto/Flameado, 115.4ms  
 image 221/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/89d6dbdfc-asb\_946.jpg: 576x640 2 Buenos, 129.6ms  
 image 222/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/8a4cb8b8-asb\_381.jpg: 576x640 1 Bueno, 113.7ms  
 image 223/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/8c1b7167-asb\_625.jpg: 576x640 5 Buenos, 112.5ms  
 image 224/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/8c269d1f-asd\_219.jpg: 448x640 1 Roto/Flameado, 170.8ms  
 image 225/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/8c2a74d6-asb\_538.jpg: 576x640 1 Roto/Flameado, 121.6ms  
 image 226/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/8cb38cd-asd\_246.jpg: 448x640 1 Roto/Flameado, 178.5ms  
 image 227/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/8d53c141-asb\_430.jpg: 576x640 2 Buenos, 108.4ms  
 ... image 228/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/8d85de50-ass\_420.jpg: 640x640 1 Roto/Flameado, 1 Sucio, 185.2ms  
 image 229/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/8dbf7010-ass\_221.jpg: 640x640 1 Sucio, 186.8ms  
 image 230/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/8dff96bb-asb\_495.jpg: 576x640 1 Bueno, 109.7ms  
 image 231/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/8f2c8756-asd\_209.jpg: 448x640 1 Roto/Flameado, 171.7ms  
 image 232/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/8fa66424-asb\_163.jpg: 576x640 1 Bueno, 119.1ms  
 image 233/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/91f46def-ass\_400.jpg: 640x640 1 Sucio, 184.7ms  
 image 234/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/924e6352-asb\_689.jpg: 576x640 4 Buenos, 98.1ms  
 image 235/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/92ae6221e-assa\_133.jpg: 640x640 1 Roto/Flameado, 1 Sucio, 189.7ms  
 image 236/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/937cc523-ass\_215.jpg: 640x640 1 Sucio, 188.5ms  
 image 237/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/941b85d7-asb\_723.jpg: 576x640 5 Buenos, 127.5ms  
 image 238/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/9446e5ff-ass\_200.jpg: 640x640 1 Roto/Flameado, 1 Sucio, 185.6ms  
 image 239/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/9476e675-asb\_776.jpg: 576x640 1 Bueno, 126.8ms  
 image 240/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/94825fb9-ass\_022.jpg: 640x640 1 Sucio, 186.3ms  
 image 241/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/94a9df59-asd\_206.jpg: 448x640 1 Roto/Flameado, 170.4ms  
 image 242/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/9531ada1-asd\_462.jpg: 512x640 2 Roto/Flameados, 216.6ms  
 image 243/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/960763af-assa\_087.jpg: 640x640 1 Sucio, 188.3ms  
 image 244/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/96947862-ass\_310.jpg: 640x640 1 Sucio, 185.7ms  
 image 245/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/979825c4-asb\_554.jpg: 576x640 1 Bueno, 115.4ms  
 image 246/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/97b9c37a-asb\_489.jpg: 576x640 2 Buenos, 73.6ms  
 image 247/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/97cb2e35-asb\_316.jpg: 576x640 1 Bueno, 127.3ms  
 image 248/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/9862f8b6-ass\_171.jpg: 640x640 1 Sucio, 188.4ms  
 image 249/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/98746aeef-ass\_001.jpg: 640x640 2 Sucios, 188.4ms  
 image 250/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/994d0ef6-asb\_581.jpg: 576x640 1 Bueno, 88.8ms  
 image 251/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/995ca21c-ass\_175.jpg: 640x640 1 Sucio, 189.1ms  
 image 252/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/995d982d-assa\_141.jpg: 384x640 2 Sucios, 205.5ms  
 image 253/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/9a05bf34-asb\_342.jpg: 576x640 1 Bueno, 125.9ms  
 image 254/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/9a43ef9f-asb\_335.jpg: 576x640 1 Bueno, 77.9ms  
 image 255/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/9ab0f0b1-ass\_159.jpg: 640x640 1 Sucio, 191.7ms  
 image 256/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/9c315e59-asd\_272.jpg: 448x640 1 Roto/Flameado, 168.7ms  
 image 257/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/9cc86881-asd\_195.jpg: 448x640 1 Roto/Flameado, 116.5ms  
 image 258/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/9cefe0c7-assa\_099.jpg: 640x640 1 Sucio, 132.1ms  
 image 259/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/9cf937e6-asd\_438.jpg: 640x640 2 Roto/Flameados, 185.8ms  
 image 260/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/9d12eaca-asb\_314.jpg: 576x640 2 Buenos, 85.2ms  
 image 261/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/9d3aac9e-asd\_093.jpg: 448x640 1 Roto/Flameado, 171.6ms  
 image 262/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/9d6d9697-assa\_136.jpg: 640x640 1 Sucio, 185.1ms  
 image 263/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/9dbae33-asd\_101.jpg: 448x640 1 Roto/Flameado, 115.0ms  
 image 264/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/9ecc4f4f-asb\_863.jpg: 576x640 1 Bueno, 121.3ms  
 ... image 265/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/9f12b6c5-asd\_235.jpg: 448x640 1 Roto/Flameado, 116.5ms  
 image 266/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/9f1da322-ass\_468.jpg: 640x640 1 Sucio, 191.5ms  
 image 267/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a0110c14-asd\_053.jpg: 448x640 1 Roto/Flameado, 172.7ms  
 image 268/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a04f0c4f-asd\_412.jpg: 640x640 2 Buenos, 185.0ms  
 image 269/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a073f93d-asb\_596.jpg: 576x640 5 Buenos, 112.5ms  
 image 270/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a088caa9-asb\_182.jpg: 576x640 2 Buenos, 126.9ms  
 image 271/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a10b24a8-asd\_052.jpg: 640x640 1 Roto/Flameado, 186.3ms  
 image 272/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a13e2733-ass\_102.jpg: 640x640 1 Sucio, 184.6ms  
 image 273/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a1616c4b-ass\_363.jpg: 640x640 3 Sucios, 128.1ms  
 image 274/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a169dc23-asd\_473.jpg: 640x640 1 Roto/Flameado, 138.8ms  
 image 275/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a18d82e1-asb\_559.jpg: 576x640 2 Buenos, 127.3ms  
 image 276/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a1a3f36e-asd\_463.jpg: 640x640 1 Roto/Flameado, 191.0ms  
 image 277/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a241be03-asd\_141.jpg: 448x640 1 Roto/Flameado, 174.4ms  
 image 278/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a2d850ef-ass\_075.jpg: 640x640 1 Sucio, 185.9ms  
 image 279/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a360a8ba-asb\_416.jpg: 576x640 1 Bueno, 113.2ms  
 image 280/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a3700f06-asd\_095.jpg: 448x640 1 Roto/Flameado, 171.3ms  
 image 281/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a3b0b06a-asd\_114.jpg: 448x640 1 Roto/Flameado, 117.1ms  
 image 282/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a3d7bce2-ass\_393.jpg: 640x640 1 Sucio, 184.4ms  
 image 283/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a3ee63c0-asd\_191.jpg: 448x640 2 Roto/Flameados, 171.3ms  
 image 284/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a445d0a9-asd\_021.jpg: 448x640 2 Buenos, 1 Roto/Flameado, 117.0ms  
 image 285/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a5181e67-asb\_403.jpg: 576x640 2 Buenos, 124.3ms  
 image 286/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a589f121-asd\_009.jpg: 448x640 1 Roto/Flameado, 118.0ms  
 image 287/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a5c90e7a-asd\_350.jpg: 448x640 1 Roto/Flameado, 170.4ms  
 image 288/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a60eaa0b-asb\_728.jpg: 576x640 4 Buenos, 116.9ms  
 image 289/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a6995746-assa\_148.jpg: 640x640 1 Sucio, 160.9ms  
 image 290/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/a9d3f6ee-asb\_539.jpg: 576x640 1 Bueno, 89.0ms  
 image 291/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/aa0c2bee-asd\_361.jpg: 448x640 1 Roto/Flameado, 169.7ms  
 image 292/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ab2371c8-ass\_386.jpg: 640x640 1 Sucio, 186.7ms  
 image 293/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ab706e50-asb\_170.jpg: 576x640 1 Bueno, 119.9ms  
 image 294/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/abebc683-asd\_015.jpg: 448x640 1 Roto/Flameado, 169.7ms  
 image 295/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ac6a0628-asd\_419.jpg: 640x640 2 Roto/Flameados, 129.8ms

image 296/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ac8cbd4f-ass\_161.jpg: 640x640 1 Sucio, 132.3ms  
image 297/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/acccb9d0-ass\_318.jpg: 640x640 1 Sucio, 183.9ms  
... image 298/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ad3d6f06-assd\_193.jpg: 448x640 1 Roto/Flameado, 169.6ms  
image 299/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/adc31719-assb\_401.jpg: 576x640 1 Bueno, 121.4ms  
image 300/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ae9177fb-assb\_970.jpg: 576x640 1 Bueno, 77.3ms  
image 301/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ae983888-assb\_127.jpg: 576x640 1 Bueno, 123.6ms  
image 302/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/af689a9a-assa\_119.jpg: 640x480 1 Sucio, 212.5ms  
image 303/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/af8d62ec-assb\_404.jpg: 576x640 3 Buenos, 126.0ms  
image 304/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/b10b9609-assb\_797.jpg: 576x640 2 Buenos, 125.3ms  
image 305/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/b1235cb1-assb\_308.jpg: 576x640 1 Bueno, 94.4ms  
image 306/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/b14f1a52-assb\_172.jpg: 576x640 2 Buenos, 89.7ms  
image 307/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/b2ba8af5-assb\_967.jpg: 576x640 1 Bueno, 125.0ms  
image 308/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/b4d95efa-assa\_109.jpg: 640x640 1 Sucio, 185.3ms  
image 309/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/b5d1cbb6-assd\_328.jpg: 448x640 1 Roto/Flameado, 116.2ms  
image 310/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/b64a6216-assb\_373.jpg: 576x640 1 Bueno, 127.4ms  
image 311/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/b65e3442-assd\_185.jpg: 448x640 1 Roto/Flameado, 116.9ms  
image 312/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/b69a3773-assb\_355.jpg: 576x640 1 Bueno, 121.9ms  
image 313/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/b7208956-ass\_069.jpg: 640x640 1 Roto/Flameado, 184.0ms  
image 314/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/b741e1ec-assb\_445.jpg: 576x640 1 Bueno, 117.6ms  
image 315/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/b82d39ae-assb\_222.jpg: 576x640 1 Bueno, 74.8ms  
image 316/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/b85a6cbf-ass\_026.jpg: 640x640 1 Sucio, 184.1ms  
image 317/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/b9923eac-assb\_437.jpg: 576x640 1 Bueno, 132.2ms  
image 318/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/b9b1388e-assd\_346.jpg: 448x640 1 Roto/Flameado, 115.2ms  
image 319/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ba06af6b-assb\_67.jpg: 576x640 1 Bueno, 136.3ms  
image 320/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/bb1e1e00-assd\_010.jpg: 448x640 1 Roto/Flameado, 117.3ms  
image 321/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/bc56b5a8-assd\_433.jpg: 640x640 1 Roto/Flameado, 135.5ms  
image 322/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/bc6f68e4-assb\_536.jpg: 576x640 1 Bueno, 126.7ms  
image 323/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/bceeb0d1-assb\_379.jpg: 576x640 1 Bueno, 118.6ms  
image 324/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/bdb6e731-assa\_026.jpg: 640x640 1 Sucio, 187.4ms  
image 325/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/bef04f36-assb\_796.jpg: 576x640 2 Buenos, 78.6ms  
image 326/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/c0c7d79a-ass\_255.jpg: 640x640 1 Sucio, 185.4ms  
image 327/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/c0e3f47f-assb\_684.jpg: 576x640 6 Buenos, 133.7ms  
image 328/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/c156b5a8-assb\_149.jpg: 576x640 1 Bueno, 121.5ms  
image 329/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/c1c23af6-ass\_474.jpg: 640x640 1 Sucio, 132.3ms  
image 330/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/c21b45a8-assb\_979.jpg: 576x640 1 Bueno, 133.6ms  
image 331/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/c2498704-ass\_442.jpg: 640x640 1 Sucio, 188.1ms  
image 332/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/c28954d5-ass\_323.jpg: 640x480 1 Sucio, 122.1ms  
image 333/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/c55a7295-ass\_305.jpg: 640x640 1 Sucio, 132.9ms  
... image 334/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/c5cd1a5-assa\_163.jpg: 640x640 1 Sucio, 137.8ms  
image 335/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/c66f98f5-assb\_173.jpg: 576x640 2 Buenos, 131.8ms  
image 336/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/c744cdf1-ass\_211.jpg: 640x640 2 Roto/Flameados, 1 Sucio, 186.9ms  
image 337/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/c7955879-assd\_367.jpg: 640x448 2 Roto/Flameados, 212.0ms  
image 338/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/c8acdc2b-assb\_528.jpg: 576x640 2 Buenos, 124.6ms  
image 339/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/c91ce765-assd\_177.jpg: 448x640 1 Roto/Flameado, 120.2ms  
image 340/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ca8b29d1-assb\_28.jpg: 576x640 1 Bueno, 124.5ms  
image 341/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/caclcfb2-assa\_037.jpg: 640x640 1 Sucio, 183.1ms  
image 342/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/caec41e9-assd\_202.jpg: 448x640 1 Roto/Flameado, 116.1ms  
image 343/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/cb46b1ac-assd\_456.jpg: 640x640 1 Roto/Flameado, 134.8ms  
image 344/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/cca3ec93-assb\_198.jpg: 576x640 1 Bueno, 126.9ms  
image 345/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/cdfaf899-assd\_240.jpg: 448x640 1 Roto/Flameado, 113.2ms  
image 346/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ce7940ec-assb\_75.jpg: 576x640 1 Bueno, 87.6ms  
image 347/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/cf3cd577-assd\_029.jpg: 640x448 1 Roto/Flameado, 113.4ms  
image 348/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/cf6cd24b-assd\_415.jpg: 640x640 1 Roto/Flameado, 187.0ms  
image 349/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/d0a4cca0-assb\_762.jpg: 576x640 2 Buenos, 126.6ms  
image 350/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/d191022a-assd\_070.jpg: 448x640 1 Roto/Flameado, 170.0ms  
image 351/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/d2ba4fbc-ass\_199.jpg: 640x640 1 Sucio, 184.6ms  
image 352/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/d3a07ad3-assd\_105.jpg: 448x640 1 Roto/Flameado, 115.7ms  
image 353/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/d4a418a6-ass\_061.jpg: 640x640 1 Sucio, 187.1ms  
image 354/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/d4e2f735-ass\_483.jpg: 640x640 1 Sucio, 186.7ms  
image 355/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/d54a5d99-assa\_031.jpg: 640x640 1 Sucio, 187.7ms  
image 356/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/d5765e71-assd\_082.jpg: 448x640 1 Roto/Flameado, 115.2ms  
image 357/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/d661e104-ass\_141.jpg: 640x640 1 Sucio, 111.3ms  
image 358/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/d6f7c6a3-assd\_036.jpg: 640x640 2 Sucios, 130.6ms  
image 359/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/d75ffcd36-assd\_482.jpg: 640x640 2 Roto/Flameados, 137.5ms  
image 360/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/d7f2735c-assa\_122.jpg: 640x640 1 Sucio, 134.8ms  
image 361/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/d90e4728-assb\_363.jpg: 576x640 2 Buenos, 126.9ms  
image 362/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/d94a6ed2-assa\_068.jpg: 640x640 1 Sucio, 186.8ms  
image 363/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/d966a9ea-ass\_068.jpg: 640x640 1 Sucio, 186.7ms  
image 364/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/da4b00c6-assb\_585.jpg: 576x640 2 Buenos, 129.4ms  
image 365/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/dbcf6f5f-assb\_518.jpg: 576x640 1 Bueno, 83.6ms  
image 366/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/dcf8a0b0-assd\_059.jpg: 640x640 1 Roto/Flameado, 187.7ms  
image 367/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/dd51648e-assb\_822.jpg: 576x640 1 Bueno, 126.3ms  
image 368/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/de790e73-assb\_497.jpg: 576x640 1 Bueno, 123.4ms  
image 369/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/dead386d-assd\_232.jpg: 448x640 1 Roto/Flameado, 173.3ms  
image 370/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/debdaaea-ass\_427.jpg: 640x640 1 Sucio, 189.3ms  
image 371/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/df398bb2-assb\_270.jpg: 576x640 1 Bueno, 129.3ms  
image 372/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/df8ecffb-assb\_965.jpg: 576x640 1 Bueno, 88.4ms  
... image 373/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e0cf16e0-assb\_307.jpg: 576x640 1 Bueno, 124.0ms  
image 374/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e1428603-ass\_338.jpg: 640x640 1 Sucio, 184.8ms  
image 375/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e19942e9-ass\_155.jpg: 640x640 1 Sucio, 187.3ms  
image 376/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e1d1be19-assd\_359.jpg: 448x640 2 Roto/Flameados, 115.9ms  
image 377/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e1df1a5f-assd\_081.jpg: 448x640 1 Roto/Flameado, 168.2ms  
image 378/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e2c19be0-ass\_364.jpg: 640x640 2 Sucios, 186.6ms  
image 379/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e2ec7228-assb\_334.jpg: 576x640 1 Bueno, 122.9ms  
image 380/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e38982f1-assd\_418.jpg: 640x640 2 Roto/Flameados, 183.6ms  
image 381/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e43a2bbb-ass\_247.jpg: 640x640 1 Sucio, 182.6ms  
image 382/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e43f62fd-assd\_046.jpg: 640x640 1 Roto/Flameado, 1 Sucio, 185.9ms  
image 383/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e4555329-assa\_147.jpg: 640x640 1 Sucio, 187.6ms  
image 384/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e4ca91b2-assb\_860.jpg: 576x640 1 Bueno, 122.5ms  
image 385/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e5a845ae-ass\_006.jpg: 640x640 1 Sucio, 187.0ms  
image 386/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e5cabe9d-assb\_562.jpg: 576x640 2 Buenos, 96.1ms  
image 387/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e5e60870-assb\_856.jpg: 576x640 1 Bueno, 79.6ms  
image 388/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e6294875-assb\_431.jpg: 576x640 1 Bueno, 134.5ms  
image 389/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e65b71ac-assb\_387.jpg: 576x640 1 Bueno, 75.6ms  
image 390/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e73afdca-assb\_328.jpg: 576x640 1 Bueno, 126.4ms  
image 391/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e7e11fb5-assb\_221.jpg: 576x640 1 Bueno, 118.7ms  
image 392/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/e8af97c1-assb\_547.jpg: 576x640 1 Bueno, 127.9ms  
image 393/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ea0e5de7-assd\_007.jpg: 640x640 1 Roto/Flameado, 192.2ms  
image 394/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ecf3473c-assb\_368.jpg: 576x640 3 Buenos, 127.3ms  
image 395/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ed4ef452-assa\_100.jpg: 640x640 1 Sucio, 194.6ms  
image 396/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ed8df870-assa\_049.jpg: 640x640 1 Sucio, 135.4ms  
image 397/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/eeda1334-assd\_002.jpg: 640x640 1 Roto/Flameado, 190.4ms  
image 398/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ef04f4df-ass\_084.jpg: 640x640 1 Sucio, 135.9ms  
image 399/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ef118b77-assd\_392.jpg: 640x640 1 Roto/Flameado, 184.2ms

```

image 400/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ef98f325-ass_020.jpg: 640x640 2 Sucios, 185.3ms
image 401/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/f0c01130-ass_368.jpg: 640x640 1 Sucio, 189.6ms
image 402/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/f0e62af0-ass_250.jpg: 448x640 1 Roto/Flameado, 170.7ms
image 403/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/f1cd8726-ass_352.jpg: 576x640 1 Bueno, 126.5ms
image 404/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/f25377ab-ass_347.jpg: 640x640 1 Roto/Flameado, 185.9ms
image 405/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/f28df491-ass_372.jpg: 576x640 1 Bueno, 96.4ms
image 406/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/f2bea20e-ass_280.jpg: 576x640 2 Buenos, 129.6ms
image 407/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/f400baf3-ass_509.jpg: 576x640 1 Bueno, 111.0ms
image 408/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/f42ae287-ass_390.jpg: 640x640 1 Sucio, 189.3ms
image 409/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/f51f5fa3-ass_813.jpg: 576x640 3 Buenos, 90.5ms
image 410/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/f5776138-ass_093.jpg: 640x640 1 Sucio, 187.3ms
image 411/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/f616bb7d-ass_212.jpg: 448x640 1 Roto/Flameado, 171.3ms
image 412/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/f6849614-ass_395.jpg: 576x640 1 Bueno, 127.5ms
image 413/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/f6c77a78-ass_533.jpg: 576x640 1 Bueno, 129.3ms
image 414/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/f6d14d4e-ass_277.jpg: 576x640 1 Bueno, 122.6ms
image 415/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/f7b67189-ass_102.jpg: 576x640 1 Bueno, 121.9ms
image 416/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/f7dc8ca6-ass_222.jpg: 640x640 1 Sucio, 189.3ms
image 417/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/f9edfba3-ass_340.jpg: 640x640 1 Sucio, 186.4ms
image 418/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/fa637d93-ass_455.jpg: 640x640 1 Sucio, 184.5ms
image 419/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/fa72838c-ass_557.jpg: 576x640 2 Buenos, 105.8ms
image 420/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/fa95eedd-ass_290.jpg: 640x640 1 Sucio, 190.3ms
image 421/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/fa999c63-ass_716.jpg: 576x640 6 Buenos, 73.1ms
image 422/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/fc173ab6-ass_772.jpg: 576x640 1 Bueno, 129.2ms
image 423/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/fc33e3d8-ass_392.jpg: 576x640 1 Bueno, 106.9ms
image 424/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/fc64ec20-ass_125.jpg: 640x640 1 Sucio, 185.2ms
image 425/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/fcfe0a53-assa_040.jpg: 640x640 1 Sucio, 172.3ms
image 426/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/fd10554a-assb_882.jpg: 576x640 1 Bueno, 130.7ms
image 427/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/fd6d84a7-assb_900.jpg: 576x640 1 Bueno, 111.5ms
image 428/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/fec62200-assa_046.jpg: 640x640 1 Sucio, 187.3ms
image 429/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ff0889e1-assd_304.jpg: 448x640 1 Roto/Flameado, 168.3ms
image 430/430 /content/drive/MyDrive/Tesis Aisladores/datasets/images/val/ffec74f5-assa_054.jpg: 640x640 1 Sucio, 190.2ms
Speed: 5.1ms preprocess, 145.9ms inference, 1.5ms postprocess per image at shape (1, 3, 640, 640)

```

```

import cv2
import matplotlib.pyplot as plt
import numpy as np

# Crear subgráficos con menos espacio entre ellos
fig, axes = plt.subplots(5, 5, figsize=(12, 12), constrained_layout=True)

# Definir el tamaño del margen (en píxeles)
margin_size = 10

# Iterar sobre los subgráficos y mostrar imágenes
for i, ax in enumerate(axes.flat):
    if i < len(preds):
        image = preds[i].plot(line_width=4, font_size=50)
        image = cv2.cvtColor(image, cv2.COLOR_BGR2RGB) # Convertir de BGR a RGB

        # Agregar un margen gris alrededor de la imagen
        image_with_border = cv2.copyMakeBorder(
            image, margin_size, margin_size, margin_size,
            borderType=cv2.BORDER_CONSTANT, value=[128, 128, 128] # Color gris
        )

        # Redimensionar a 640x640 píxeles
        image_resized = cv2.resize(image_with_border, (640, 640), interpolation=cv2.INTER_AREA)

        ax.imshow(image_resized)
        ax.axis("off")
    else:
        ax.axis("off")

# Ajustar los espacios automáticamente
plt.tight_layout()
plt.subplots_adjust(wspace=0.01, hspace=0.01)
plt.savefig('Predicciones.jpg', dpi=900)
plt.show()

```

```

... /tmp/ipython-input-4149990344.py:32: UserWarning: The figure layout has changed to tight
plt.tight_layout()

```



Fuente: Elaboración propia