



UNIVERSIDAD POLITÉCNICA SALESIANA

SEDE GUAYAQUIL

CARRERA DE ELECTRICIDAD

SISTEMA INTELIGENTE DE DIAGNÓSTICO TERMOGRÁFICO ASISTIDO POR INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN TEMPRANA DE ANOMALÍAS EN EQUIPOS DE SUBESTACIONES ELÉCTRICAS DE GUAYAQUIL.

Trabajo de titulación previo a la obtención del

Título de Ingeniero Eléctrico

AUTORES: Jordy Steves Vargas Cauja

Ronny Jesús Castillo Jiménez

TUTOR: Ing. Holger Jorge Santillán Carranza

Guayaquil – Ecuador

2026


CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE TITULACIÓN

Nosotros, Jordy Steves Vargas Cauja con documento de identificación N° 0956036420 y Ronny Jesús Castillo Jiménez con documento de identificación N° 0927853663 manifestamos que:

Somos los autores y responsables del presente trabajo y autorizamos a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Guayaquil, 15 de enero del año 2026

Atentamente;



Jordy Steves Vargas Cauja
CI: 0956036420



Ronny Jesús Castillo Jiménez
CI: 0927853663


CESIÓN DE DERECHOS DE AUTOR

Nosotros, Jordy Steves Vargas Cauja con número de identificación N° 0956036420 y con Ronny Jesús Castillo Jiménez número de identificación N° 0927853663 , expresamos nuestra voluntad y por medio del presente documento cedemos a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de lo que somos autores del Proyecto Técnico: “SISTEMA INTELIGENTE DE DIAGNÓSTICO TERMOGRÁFICO ASISTIDO POR INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN TEMPRANA DE ANOMALÍAS EN EQUIPOS DE SUBESTACIONES ELÉCTRICAS DE GUAYAQUIL.”, el cual ha sido desarrollado para optar por el título de Ingeniero en Electricidad, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribimos este documento en el momento que hacemos la entrega del trabajo final en el formato digital a la biblioteca de la Universidad Politécnica Salesiana.

Guayaquil, 15 de enero del año 2026

Atentamente;



Jordy Steves Vargas Cauja
CI: 0956036420




Ronny Jesús Castillo Jiménez
CI: 0927853663

CERTIFICADO DE DIRECCIÓN DE TRABAJO DE TITULACIÓN

Yo, HOLGER JORGE SANTILLAN CARRANZA con documento de identificación N° 0916303134 docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: “SISTEMA INTELIGENTE DE DIAGNÓSTICO TERMOGRÁFICO ASISTIDO POR INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN TEMPRANA DE ANOMALÍAS EN EQUIPOS DE SUBESTACIONES ELÉCTRICAS DE GUAYAQUIL.”, realizado por Jordy Steves Vargas Cauja con número de identificación N° 0956036420 y Ronny Jesús Castillo Jiménez con número de identificación N°0927853663, obteniendo como resultado final el trabajo de titulación bajo la opción Proyecto Técnico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Guayaquil, 15 de enero del año 2026

Atentamente;



Holger Jorge Santillán Carranza

CI: 0916303134

DEDICATORIA

Dedico este trabajo de titulación a mi querida familia: a mi padre, mi madre y mis hermanos a mis abuelitos y mis tíos y a mi novia que siempre estuvo hay desde comencé mi carrera universitaria, los que, con su amor, consejos y apoyo incondicional, han representado un soporte esencial durante mis cuatro años de preparación como futuro profesional. También dedico este logro a mi tío Segundo y tía Maritza quienes me dieron el apoyo cuando más lo necesite y mi abuelito también, Mis Padres quienes me han motivado a ofrecer lo mejor de mí en cada fase de mi vida, mostrando confianza, fe y perseverancia en las habilidades que Dios me ha otorgado para afrontar cada reto que la vida me ha presentado.

Jordy Steves Vargas Cauja

Este trabajo de tesis está destinado a todos los que me acompañaron en este significativo proceso, no solo en términos académicos, sino también en cuanto a mi desarrollo como ser humano y persona. Dedico este logro a mi familia, en particular, porque con su apoyo incondicional, paciencia, sacrificio y consejos se han convertido para mí en la principal fuente de motivación para no rendirme ante los obstáculos y continuar avanzando en cada fase de mi vida universitaria.

Igualmente, en este trabajo quiero rendir homenaje a mis amigos y compañeros, quienes me acompañaron en instantes de esfuerzo, aprendizaje y superación, y que ayudaron a que este trayecto fuera más llevadero y significativo.

Este logro no es únicamente mío, sino de todas aquellas personas que creyeron en mí, me brindaron su apoyo y me impulsaron a seguir luchando por mis metas y sueños.

Ronny Jesús Castillo Jiménez

AGRADECIMIENTO

Agradezco a Dios y a la Virgen María por brindarme la oportunidad de gozar de la vida, la salud y el vigor que necesito para terminar mi carrera profesional. A lo largo de mi carrera universitaria, su guía y bendiciones diarias han sido la fortaleza más importante. Mis padres me han respaldado con empeño y cariño en cada etapa de este camino, superando cada dificultad con optimismo y determinación.

Mi agradecimiento al Ingeniero Holger Santillán y al ingeniero Luis Galarza por colaborar en mi formación académica con su paciencia, sus actitudes de apoyo y sus conocimientos profesionales. Tus esfuerzos y tu dedicación para transmitir tu experiencia han sido esenciales para hacer realidad mi proyecto de titulación, proporcionándome valores y lecciones que influirán en mi futuro.

Jordy Steves Vargas Cauja

Primeramente, agradezco a Dios por darme vida, salud, fortaleza y perseverancia para terminar esta etapa crucial de mi desarrollo profesional.

Agradezco a mis padres por su apoyo incondicional, su esfuerzo perseverante y sus consejos prudentes durante todos estos años de educación universitaria. Ellos han sido un soporte esencial, en lo académico y en lo personal, y gracias a su dedicación, confianza y motivación hemos logrado este importante objetivo.

Ronny Jesús Castillo Jiménez

ÍNDICE DE CONTENIDO

CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE TITULACIÓN	ii
CESIÓN DE DERECHOS DE AUTOR	iii
CERTIFICADO DE DIRECCIÓN DE TRABAJO DE TITULACIÓN	iv
DECICATORIA	v
AGRADECIMIENTO	vi
ÍNDICE DE CONTENIDO	vii
ÍNDICE DE FIGURAS	xii
ÍNDICE DE TABLAS	xiv
RESUMEN	xv
ABSTRACT	xvi
ACRONIMOS	xvii
CAPITULO I	1
1.1. TITULO.....	1
1.2. ANTECEDENTES.....	1
1.3. INTRODUCCIÓN	2
1.4. PLANTEAMIENTO DEL PROBLEMA.....	3
1.5. JUSTIFICACIÓN.....	4
1.6. ALCANCE.....	5
1.7. BENEFICIARIOS	5
1.8. OBJETIVOS.....	6
1.8.1. OBJETIVO GENERAL	6
1.8.2. OBJETIVOS ESPECÍFICOS	6
CAPITULO II.....	7

2.1.	FUNDAMENTO TEÓRICO.....	7
2.1.1.	TERMOGRAFÍA INFRARROJA	7
2.1.2.	CÁMARA TERMOGRÁFICA FLIR T640.....	9
2.1.3.	EMISIVIDAD Y FACTORES QUE AFECTAN LA MEDICIÓN TÉRMICA..	9
2.1.4.	ANOMALÍAS TÉRMICAS EN EQUIPOS ELÉCTRICOS	10
2.1.5.	SUBESTACIONES ELÉCTRICAS	11
2.1.6.	ESQUEMA UNIFILAR DE UNA SUBESTACIÓN ELÉCTRICA	11
2.2.	CLASIFICACIÓN DE LAS SUBESTACIONES ELÉCTRICAS	12
2.2.1.	COMPONENTES DE UNA SUBESTACIÓN ELÉCTRICA.....	12
2.2.2.	INTERRUPTOR DE POTENCIA DE 69 KV TIPO GCB	13
2.2.3.	TRANSFORMADOR DE PODER.....	15
2.2.4.	SECCIONADOR PRINCIPAL DE MEDIA TENSIÓN	17
2.2.5.	RECONECTADORES DE MEDIA TENSIÓN	19
2.2.6.	MONITOREO TÉRMICO EN SUBESTACIONES	21
2.2.7.	MANTENIMIENTO PREDICTIVO EN SUBESTACIONES ELÉCTRICA..	22
2.2.8.	TÉCNICAS DE MANTENIMIENTO PREDICTIVO	22
2.2.9.	VENTAJAS DEL MANTENIMIENTO PREDICTIVO	22
2.2.10.	LIMITACIONES DEL ENFOQUE TRADICIONAL.....	23
2.2.11.	INTELIGENCIA ARTIFICIAL Y APRENDIZAJE AUTOMÁTICO	23
2.1.12.	APRENDIZAJE SUPERVISADO Y NO SUPERVISADO	23
2.3.	REGULACIÓN ARCONEL 004/01, NIVEL DE VOLTAJE Y CALIDAD DEL PRODUCTO.....	24
2.3.1.	APRENDIZAJE PROFUNDO.....	26
2.3.2.	VENTAJAS DE LA INTELIGENCIA ARTIFICIAL EN SISTEMAS ELÉCTRICOS	26
2.3.3.	REDES NEURONALES CONVOLUCIONALES (CNN)	26

2.3.4.	APLICACIÓN DE INTELIGENCIA ARTIFICIAL EN TERMOGRAFÍA ELÉCTRICA	27
2.3.5	AUTOMATIZACIÓN DEL DIAGNÓSTICO TÉRMICO	27
2.3.6.	CLASIFICACIÓN DE SEVERIDAD TÉRMICA	27
2.3.7.	APOYO A LA TOMA DE DECISIONES EN MANTENIMIENTO	27
2.3.8.	PROCESAMIENTO DIGITAL DE IMÁGENES TÉRMICAS	27
2.3.9.	GOOGLE COLAB	28
CAPITULO III		29
3.1.	DESCRIPCIÓN DEL CASO DE ESTUDIO	29
3.2.	METODOLOGIA	29
3.2.1.	PROTOTIPO PROPUESTO	30
3.2.2.	ENFOQUE METODOLÓGICO	31
3.2.3.	RECOPIACIÓN DE DATOS TERMOGRÁFICOS DE EQUIPOS ELÉCTRICOS	31
3.2.4.	IMPORTACIÓN Y FUNCIÓN DE LAS LIBRERÍAS UTILIZADAS	34
3.2.4.1.	OPENCV (CV2).....	34
3.2.4.2.	NUMPY (NUMPY)	35
3.2.4.3.	MATPLOTLIB (MATPLOTLIB.PYPLOTT)	35
3.2.4.4.	TENSORFLOW (TENSORFLOW)	35
3.2.4.5.	KERAS – MODELOS	36
3.3.	PRE PROCESAMIENTO Y CONVERSIÓN DE INFORMACIÓN VISUAL A DATOS TÉRMICOS.....	36
3.3.1.	IDENTIFICACIÓN DE PUNTOS CRÍTICOS Y PATRONES TÉRMICOS... 37	
3.3.2.	CLASIFICACIÓN DE SEVERIDAD TÉRMICA SEGÚN NORMATIVAS TÉCNICAS.....	37

3.3.3.	ANÁLISIS DE ÁREAS CRÍTICAS Y EVALUACIÓN ESPACIAL DEL RIESGO.....	38
3.3.4.	VISUALIZACIÓN AVANZADA DE INFORMACIÓN TÉRMICA.....	38
3.3.5.	PREPARACIÓN DE DATOS PARA EL ENTRENAMIENTO DEL MODELO DE INTELIGENCIA ARTIFICIAL.....	39
3.3.6.	DISEÑO DEL MODELO DE APRENDIZAJE PROFUNDO	39
3.3.7.	ENTRENAMIENTO Y VALIDACIÓN DEL MODELO INTELIGENTE.....	40
3.3.8.	EVALUACIÓN DEL SISTEMA AUTOMATIZADO DE DIAGNÓSTICO TERMOGRÁFICO.....	40
3.4.	IMPORTACIÓN Y FUNCIÓN DE LAS LIBRERÍAS UTILIZADAS	41
3.4.1.	DETECCIÓN AUTOMÁTICA DE PUNTOS CALIENTES.....	43
3.4.2.	PRE-PROCESAMIENTO Y CONVERSIÓN DE INFORMACIÓN VISUAL A DATOS TÉRMICOS.....	45
3.4.3.	IDENTIFICACIÓN DE PUNTOS CRÍTICOS Y PATRONES TÉRMICOS...	46
3.4.4.	CLASIFICACIÓN DE SEVERIDAD TÉRMICA SEGÚN NORMATIVAS TÉCNICAS.....	48
3.4.5.	VISUALIZACIÓN AVANZADA DE INFORMACIÓN TÉRMICA.....	49
3.4.6.	PREPARACIÓN DE DATOS PARA EL ENTRENAMIENTO DEL MODELO DE INTELIGENCIA ARTIFICIAL.....	51
3.4.7.	DISEÑO DEL MODELO DE APRENDIZAJE PROFUNDO	52
3.4.8.	ENTRENAMIENTO Y VALIDACIÓN DEL MODELO INTELIGENTE.....	54
CAPITULO IV		57
4.	IMPLEMENTACION DE LA METODOLOGÍA Y VALIDACIÓN DE RESULTADOS OBTENIDOS.....	57
4.1.	PRUEBAS DE PUNTOS CALIENTES EN TRANSFORMADORES DE CORRIENTE.....	58

4.1.2.	ANÁLISIS DE LA PRUEBA EN TRANSFORMADORES DE CORRIENTE	
	60	
4.2.	PRUEBAS DE PUNTOS CALIENTES EN FUSIBLES DE 69 KV	62
4.2.1.	ANÁLISIS DE LA PRUEBA DE FUSIBLE DE 69 KV.....	64
4.3.	PRUEBAS DE PUNTOS CALIENTES EN INTERRUPTOR DE PODER.....	66
4.3.1.	ANÁLISIS DE LA PRUEBA DE INTERRUPTOR DE PODER.....	68
4.4.	PRUEBAS DE PUNTOS CALIENTES EN SECCIONADORES	70
4.4.1.	ANÁLISIS DE LA PRUEBA DE SECCIONADORES	72
4.5.	PRUEBAS DE PUNTOS CALIENTES EN CADENA DE AISLADORES	74
4.5.1.	ANÁLISIS DE LA PRUEBA DE CADENA DE SECCIONADORES	75
4.6.	ANÁLISIS FINAL.....	77
4.7.	PROPUESTA SOBRE SISTEMA INTELIGENTE DE DIAGNÓSTICO	
	TERMOGRÁFICO.....	78
4.7.1.	APLICACIÓN EN LA VIDA REAL.....	80
4.7.2.	BENEFICIOS DE LA PROPUESTA	80
CAPITULO V.....		81
5.1.	CONCLUSIONES	81
5.2.	RECOMENDACIONES	82
CAPITULO VI.....		83
6.	REFERENCIAS BIBLIOGRAFICAS	83
ANEXOS		86
7.1.	CODIGO DE UTILIZACION PARA EL SISTEMA DE IMAGENES	
	TERMOGRAFICAS	86

ÍNDICE DE FIGURAS

Figura 1. Diagrama De Sistema Unifilar _____	11
Figura 2. Interruptor de Potencia _____	14
Figura 3. Termografía de Interruptor de Potencia _____	14
Figura 4. Transformador de Potencia _____	16
Figura 5. Termografía de Puntos Calientes _____	16
Figura 6. Transformador de Potencia _____	17
Figura 7. Seccionador Principal de Media Tensión _____	18
Figura 8. Termografía Seccionador Principal de Media Tensión _____	19
Figura 9. Reconectador de Media Tensión _____	20
Figura 10. Termografía de Reconectador de Media Tensión _____	21
Figura 11. Mantenimiento Predictivo En Subestaciones Eléctrica _____	24
Figura 12. Google Colab _____	28
Figura 13. Diagrama De Flujo del Procedimiento del Trabajo _____	29
Figura 14. Prototipo Propuesto _____	30
Figura 15. Software FLIR _____	31
Figura 16. Importación De Imágenes Software FLIR _____	32
Figura 17. Imágenes Termográficas De Equipos De La Subestación _____	32
Figura 18. Transformador De Poder Con Alta Temperatura En Terminales De Bushing _____	33
Figura 19. Colab De Google _____	34
Figura 20. Importación De Librerías Y Carga De Imágenes _____	42
Figura 21. Mensaje De Análisis En One Drive _____	42
Figura 22. Identificación Del Punto Caliente En Imagen Termográfica. _____	43
Figura 23. Clasificación De Severidad _____	44
Figura 24. Resultado Máximo Térmico _____	45
Figura 25. Resultado de Generación del Mapa Térmico _____	46
Figura 26. Visualización Código y Exportación de Mapa Térmico _____	47
Figura 27. Resultado De La Simulación De Mapa Térmico _____	47
Figura 28. Código De La Generación Del Mapa De Severidad Térmicas _____	49
Figura 29. Visualización Del Código Mapa De Severidad _____	50
Figura 30. Mapa De Severidad Térmicas _____	50

Figura 31. Código Datos, Modelos De Aprendizaje _____	52
Figura 32. Compilación y Entrenamiento Del Modelo _____	53
Figura 33. Resultados De Mejoría De La Prueba De Imagen _____	54
Figura 34. Mapa de severidad Espacial _____	55
Figura 35. Mapa De Severidad Por Modelo De Predicción De La IA _____	56
Figura 36. Batería De Transformadores De Corriente _____	59
Figura 37. Fusibles De 69 KV _____	63
Figura 38. Interruptor De Poder _____	67
Figura 39. Seccionadores _____	71
Figura 40. Cadena De Aisladores _____	75

ÍNDICE DE TABLAS

Tabla 1. Norma ANSI NETA ATS _____	8
Tabla 2. De Incidencias En Altas Temperatura Por Equipos De Subestación _____	10
Tabla 3. Límites de tensiones en porcentajes % _____	25
Tabla 4. Abreviaturas En La Categorización Del Voltaje ARCONEL 005/18 _____	25
Tabla 5. Niveles de Voltaje establecidos en el ARCONEL001/04 _____	25
Tabla 6. Datos De Grados Celsius _____	48
Tabla 7. Datos De Mapa De Severidad _____	56
Tabla 8. Medición De Datos Batería De Transformador _____	60
Tabla 9. Análisis Térmico Batería De Transformador _____	61
Tabla 10. Medición De Datos De Fusible 69 Kv _____	64
Tabla 11. Análisis Térmico De Fusible 69 Kv _____	65
Tabla 12. Medición De Datos Interruptor De Poder _____	68
Tabla 13. Análisis Térmico Por Interruptor De Poder _____	69
Tabla 14. Medición De Datos Pruebas De Seccionadores _____	72
Tabla 15. Análisis Térmico De Seccionadores _____	73
Tabla 16. Medición De Datos Pruebas De Cadenas De Seccionadores _____	76
Tabla 17. Análisis Térmico Cadena De Aisladores ANSI/NETA _____	76

RESUMEN

El actual trabajo de titulación se concentra en el análisis de un sistema inteligente de diagnóstico termográfico basado en métodos de inteligencia artificial, con el objetivo de identificar precozmente anomalías térmicas en los dispositivos de las subestaciones eléctricas urbanas de la ciudad de Guayaquil. El incremento constante de la demanda de energía, junto con las condiciones ambientales propias de la región, somete a estas instalaciones a mayores exigencias operativas, lo que hace indispensable fortalecer los esquemas de mantenimiento predictivo para garantizar la prolongación y confiabilidad del sistema eléctrico.

La investigación se justifica en el estudio de presentación de imágenes termográficas obtenidas de equipos considerados críticos dentro de las subestaciones, como interruptores de potencia de 69 kV tipo GCB, transformadores de poder y seccionadores principales de media tensión. La termografía infrarroja se ejecuta como una herramienta de monitoreo no invasiva, lo que permite ayudar el procedimiento térmico de los equipos mientras se localiza se utiliza en operación normal, sin afectar la imagen del sistema energía eléctrico.

A partir de las imágenes empleadas, se evalúa a ingresar a un modelo de inteligencia artificial fundamentado en algoritmos de un sistema de evaluación profunda, prácticamente en las redes neuronales convolución. Este modelo tiene como finalidad reconocer y clasificar de manera automática las anomalías térmicas, considerando su nivel de severidad. La implementación de este sistema automatizado de diagnóstico tiene como objetivo disminuir la dependencia del análisis manual, desarrollar la consistencia de los datos encontrado y disminuir el procedimiento de decidir cómo afrontar el mantenimiento.

Los objetivos esperados de esta evaluación aportan a la mejoría de la administración del mantenimiento en unas subestaciones eléctricas, disminuyendo la probabilidad de fallas inesperadas, extendiendo la vida útil de los equipos y aumentando la seguridad operativa. Además, este trabajo contribuye a la creación de conocimientos aplicados en el área de la ingeniería eléctrica, al integrar la termografía infrarroja, la visión computacional y la inteligencia artificial, en línea con las tendencias actuales de las tendencias actuales de la Industria 4.0.

ABSTRACT

In order to detect thermal anomalies in Guayaquil's electrical substation equipment early on, this thesis focuses on developing an intelligent thermographic diagnostic system that is supported by artificial intelligence approaches. Predictive maintenance plans must be strengthened to guarantee the continuity and dependability of the electrical service due to the region's environmental conditions and the ongoing rise in energy consumption, which puts these facilities under increased operating demands.

The study is based on the examination of thermographic pictures taken from important substation equipment, including main medium-voltage disconnectors, power transformers, and 69 kV GCB-type circuit breakers. As a non-invasive monitoring technique, infrared thermography makes it possible to assess the equipment's thermal behavior while it is operating normally without compromising service delivery.

Based on the captured images, an artificial intelligence model is designed and trained using deep learning algorithms, particularly convolutional neural networks. This model aims to automatically identify and classify thermal anomalies, considering their severity level. The implementation of this automated diagnostic system seeks to reduce reliance on manual analysis, provide greater consistency in results, and facilitate decision-making in maintenance planning.

The expected results of this study contribute to improved maintenance management in electrical substations, reducing the probability of unexpected failures, extending equipment lifespan, and strengthening operational safety. Furthermore, this work contributes to the development of applied knowledge in the field of electrical engineering by integrating infrared thermography, computer vision, and artificial intelligence, in line with current Industry 4.0 trends.

Keywords: Artificial Intelligence, Electrical Substation, Thermography, Regulations, System Reliability.

ACRONIMOS

CNEL: Corporación Nacional de Electricidad.

CYMDIST: Software de simulación para sistemas de distribución eléctrica.

ARCONEL: Agencia de regulación y control de energía.

S/E: Subestación Eléctrica.

SCADA: Supervisory Control and Data Acquisition.

BIL: Basic Insulation Level.

MVA: mega Voltio-amperio.

KCMIL: Unidad de medida de sección de conductores eléctricos.

ACSR: Aluminum Conductor Steel Reinforced

RMS: Root Mean Square.

SNI: Sistema Nacional Interconectado.

MT: Media Tensión.

AT: Alta Tensión.

BT: Baja Tensión.

IEEE: Instituto de Ingenieros Eléctricos y Electrónicos.

AT: Alto tensión.

BT: Bajo tensión.

MV: Medio Voltaje.

DC: Corriente Directa.

AC: Corriente Alterna.

kVA: Kilovoltio-amperio.

kWh: Kilovatio/hora.

kV: Kilovoltio.

pu: Por Unidad

CAPITULO I

1.1. TITULO

Sistema inteligente de diagnóstico termográfico asistido por inteligencia artificial para la detección temprana de anomalías en equipos de subestaciones eléctricas de Guayaquil.

1.2. ANTECEDENTES

El aumento constante de la solicitud de energía eléctrica en las principales urbes de Ecuador, sobre todo en Guayaquil, ha alcanzado notablemente las necesidades operativas de las subestaciones eléctricas. Estos sistemas constituyen elementos clave del sistema eléctrico de potencia, al contar con maquinaria de un valor económico y alta criticidad, cuya falta puede causar interrupciones prolongadas en el servicio y pérdidas económicas significativas

Las estaciones eléctricas encontradas en la región Costa están sujetas a condiciones ambientales difíciles, como demasiadas temperaturas, asumida a niveles de humedad y la influencia de la contaminación salina. Este ambiente de trabajo afecta de manera directa el desgaste progresivo de los materiales aislantes y eleva la probabilidad de incremento de fallos térmicos, sobre todo en conexiones eléctricas, barras, transformadores y dispositivos de maniobra. Circunstancias, el mantenimiento predictivo se vuelve crucial para preservar la estabilidad y fiabilidad del sistema eléctrico [1].

Entre las técnicas a desarrollar para examinar el estado térmico de los equipos energizados, la termografía infrarroja refleja por su eficacia en la detección de puntos calientes y fugas térmicas. Sin embargo, en numerosos casos, el estudio de los termogramas sigue llevándose a cabo manualmente, dependiendo del juicio y la pericia del equipo técnico. Este método de examinar puede causar variaciones en los diagnósticos y complicaciones en la correcta priorización de las actividades de mantenimiento.

1.3. INTRODUCCIÓN

El crecimiento económico, industrial y social de una ciudad se ve afectado directamente por la confiabilidad y la persistencia del suministro eléctrico en este conocimiento, las subestaciones eléctricas tienen un papel importante porque permiten una apropiada transformación y distribución de la energía hasta que llegar a las personas.

La termografía infrarroja es un procedimiento no invasivo que se utiliza en el mantenimiento predictivo de los equipos de subestaciones eléctricas con el objetivo de detectar ciertos fallos antes de que interfieran con el funcionamiento del sistema. Esta técnica posibilita la estabilización de fluctuaciones térmicas en equipos dañados sin tener que parar su funcionamiento, lo cual es esencial para preservar la continuidad del servicio eléctrico. Se estudia como un enfoque proactivo que pronostica y previene fallas de equipos antes de que ocurran, asegurando así la confiabilidad y eficiencia del sistema eléctrico. Esto se determina la utilizando tecnologías como termografía infrarroja (IRT), que descubre y analiza variaciones de temperatura en la superficie de los equipos para encontrar posibles fallas como sobrecalentamiento, corrosión o defectos de aislamiento [2].

En Guayaquil, los estudios termográficos son una parte de las tareas rutinarias de realizar mantenimientos preventivos. No obstante, el volumen de imágenes térmicas se aumentado de una gran manera, la complicidad del desarrollo de una indagación apropiada y discreto si se basa en ciertos métodos manuales. Afrontando esta realidad, el uso de herramientas de inteligencia artificial se muestra como una alternativa viable para un apoyo en el diagnóstico, disminuir toda la dependencia del criterio uno mismo y ver cómo se toman decisiones en la predicción del mantenimiento [3].

Este análisis propone la aplicación de una metodología que agreguemos el uso de la termografía infrarroja y estudio automático para encontrar con antelación ciertas anomalías térmicas en el equipamiento de subestaciones eléctricas de la provincia de Guayas, situada en la urbe de Guayaquil. Con esto, se pretende elevar la confiabilidad operativa del sistema eléctrico en Guayaquil y reducir la ocurrencia de fallas imprevistas.

1.4. PLANTEAMIENTO DEL PROBLEMA

Las subestaciones eléctricas se trabajan en un estado de ambiente climático especialmente severo en la región costera del Ecuador, donde se encuentra temperaturas altas, una elevada humedad y una constante aparición de unos agentes salinos. El agotamiento aumentado de los materiales aislantes y la presencia de problemas térmicos, en especial en las conexiones del eléctrico, las barras aislamiento, los dispositivos para la seguridad de la maniobra y los transformadores de poder, se ven directamente con fallas por estas condiciones ambientales. Es esencial usar tipos de métodos de mantenimiento predictivo para tener la confiabilidad operacional del sistema eléctrico en país [4].

Entre las actividades a evaluar para examinar el comportamiento térmico de los equipos en servicio, la termografía infrarroja que se establece un lugar destacado debido a su capacidad para la visualización de las anomalías de temperatura sin necesidad de molestar la operación. Sin embargo, en el ámbito operativo, el estudio de los termogramas suele necesitar del juicio del personal técnico de la inspección, lo que puede ingresar variaciones en la interpretación de los datos encontrado e imposibilitar una adecuada jerarquización del resultado de mantenimiento [5].

En este estudio, la ampliación de las herramientas basadas en inteligencia artificial ha franco nuevas medios para el procesamiento automático de representaciones pictóricas térmicas. En particular, las redes neuronales convolucionales han mostrado un nivel alto de desempeño en la visualización de patrones térmicos irregulares, permitiendo resultado de evaluaciones realizada más uniformes y confiables. Diversas experiencias documentadas a nivel internacional dicen que la integración de la termografía infrarroja con técnicas de inteligencia artificial contribuye de manera esencial a optimar la calidad del diagnóstico y a reducir la ocurrencia de problemas no previstas en los sistemas eléctricos de potencia [6].

1.5. JUSTIFICACIÓN

El uso del estudio termográfico es un componente esencial dentro de las tácticas de mantenimiento predictivo aplicadas a instalaciones eléctricas, debido a su capacidad para detectar incrementos anómalos de temperatura y condiciones de sobrecarga antes de que estas deriven en fallas de carácter crítico. En este sentido, El uso de técnicas de visión computacional e inteligencia artificial implica un progreso importante desde el punto de vista técnico e industrial, ya que permite la automatización del proceso de diagnóstico y reduce la dependencia del análisis que solo se basa en la experiencia del personal técnico [7].

La implementación de sistemas de este tipo en las subestaciones eléctricas de la ciudad de Guayaquil permitiría optimizar la gestión del mantenimiento, reduciendo la ocurrencia de interrupciones no programadas y fortaleciendo las condiciones de seguridad operativa. Asimismo, la identificación temprana de anomalías térmicas contribuye a evitar pérdidas energéticas, mitigar el riesgo de incendios y prolongar la duración de los equipos de potencia involucrados en el sistema eléctrico.

Desde una perspectiva académica, el desarrollo de este proyecto favorece la formación integral del ingeniero eléctrico al integrar conocimientos de termografía infrarroja, procesamiento digital de imágenes y aprendizaje automático. Este enfoque promueve la adopción de modelos de mantenimiento sustentados en el examen de datos y el uso de instrumentos inteligentes, en concordancia con los principios de la Industria 4.0.

De esta manera, la investigación aporta tanto al fortalecimiento del desarrollo tecnológico como a la generación de conocimiento aplicado en el ámbito de la ingeniería eléctrica contemporánea.

1.6. ALCANCE

La investigación se establece en un estudio y proceso de imágenes termográficas logradas de dispositivos eléctricos colocados en subestaciones restringidas en la ciudad de Guayaquil. En este marco, se propone un desarrollo y la apreciación de un estilo basado en inteligencia artificial destinado a la identificación y clasificación de anomalías térmicas. Sin embargo, la importancia del compromiso se limita al análisis y validación de un estudio propuesto, sin considerar el diseño físico de nuevas subestaciones ni su aplicación o implementación a nivel comercial.

1.7. BENEFICIARIOS

Los beneficiarios del proyecto técnico creado se clasifican en tres grupos principales:

- La Universidad Politécnica Salesiana implementará un proyecto técnico como reconocimiento a los graduados como magníficos profesionales.
- Las compañías eléctricas, en términos generales, emplean el soporte de la técnica de predicción termográfica para sugerir soluciones eficaces frente a eventualidades que surgen por las altas tasas de fallos.
- Los clientes del sistema de distribución eléctrica, que incluyen a empresas y negocios grandes, buscan incrementar sus beneficios brindando servicios adecuados en su zona, los cuales cuentan con un índice superior de fiabilidad del suministro eléctrico en circunstancias de emergencia.

1.8 OBJETIVOS

1.8.1. OBJETIVO GENERAL

Desarrollar un sistema inteligente de diagnóstico termográfico asistido por inteligencia artificial para la detección temprana de anomalías térmicas en equipos de subestaciones eléctricas de Guayaquil.

1.8.2. OBJETIVOS ESPECÍFICOS

- Adquirir y analizar imágenes termográficas de los equipos eléctricos mediante el uso de cámaras infrarrojas y técnicas de visión computacional, con el propósito de obtener información térmica confiable que permita identificar patrones de comportamiento relevantes.
- Desarrollar un modelo de inteligencia artificial basado en algoritmos de aprendizaje profundo, utilizando las imágenes previamente procesadas para la detección y clasificación automática de anomalías térmicas.
- Integrar un sistema automatizado de diagnóstico termográfico, incorporando el modelo entrenado en una plataforma de análisis que facilite la detección temprana de fallas y contribuya a mejorar la confiabilidad operativa de las subestaciones eléctricas.

CAPITULO II

2.1. FUNDAMENTO TEÓRICO

Los fundamentos teóricos que respaldan la investigación se establecen en este capítulo. Con ese objetivo, se de evaluar los principales fundamentos en la termografía infrarroja, el uso térmico de los equipos eléctricos y la estructura global de las subestaciones eléctricas. Asimismo, se analiza la utilización de métodos de inteligencia artificial para el análisis automático de imágenes térmicas. En conclusión, estos asuntos prometen la base técnica que se necesita para entender cómo la realización del sistema inteligente propuesto.

2.1.1. TERMOGRAFÍA INFRARROJA

La termografía infrarroja se emplea como es una táctica de diagnóstico no destructiva que se apoya en la captación de la energía térmica emitida por los cuerpos el espectro electromagnético en su rango infrarrojo. Todo material que se encuentre a una temperatura superior al cero absoluto ($-273,15$ °C) emite radiación térmica, cuya intensidad está determinada tanto por su temperatura como por características propias del material, entre las que destaca la emisividad [7].

La termografía infrarroja es un proceso no invasivo que se habilita a desarrollar la repartición de temperatura en la superficie de la zona y evaluar. Cuando se emplea junto con los métodos tradicionales de monitoreo de edificios, se transforma en un instrumento útil para visualizar imperfecciones en la envoltura de los edificios, puentes térmicos y filtraciones de aire y humedad. El alcance de este trabajo es demostrar los usos cualitativos de la termografía infrarroja en la edificación y evaluar el impacto que tienen sobre las medidas cuantitativas ciertas fuentes de error frecuentes. En primer lugar, para ello, se explica de manera breve cómo opera una cámara termográfica y cuáles son los posibles orígenes de error en los termogramas [7], [8].

Esta característica contribuye a mantener la estabilidad del servicio eléctrico y a eliminar los riesgos para el personal técnico. Por estas razones, la termografía infrarroja se ha incorporado de manera habitual en las transmisiones de mantenimiento predictivo aplicados en subestaciones eléctricas.

La interpretación de las imágenes térmicas se lleva a cabo considerando el incremento de temperatura establecido en la Norma ANSI NETA, En función del nivel térmico detectado, se determina el grado de criticidad del componente evaluado, donde el color naranja representa una condición de baja severidad (fase de monitoreo), el color amarillo corresponde a una condición de severidad media (intervención en el siguiente mantenimiento programado) y el color rojo indica una condición crítica que requiere corrección inmediata.

De acuerdo a los estudios realizados en las subestaciones según **Tabla 1**, se expone la mayor incidencia en altas temperaturas en los siguientes equipos:

Diagnóstico DE La Norma ANSI NETA, Que Determina El Incremento De La Temperatura.			
Categoría	Grados Celsius	Rango	ACCION
1	10 a 20° C	BAJO	Fase De Observación
2	20 a 60° C	MEDIO	Remediar El Próximo Mantenimiento
3	\geq a 60° C	ALTO	Subsanar Inmediatamente

Tabla 1. Norma ANSI NETA ATS

2.1.2. CÁMARA TERMOGRÁFICA FLIR T640

La cámara termográfica FLIR T640 corresponde a un equipo de uso profesional desarrollado para la inspección de instalaciones eléctricas e industriales que demandan elevados niveles de precisión en la medición térmica. Su intrepidez infrarroja de 640×480 píxeles, junto con una sensibilidad térmica inferior a $0,04$ °C. La FLIR T640 incorpora, además, lentes intercambiables, funciones avanzadas de análisis radiométrico y sistemas de enfoque automático, características que facilitan la elaboración de informes técnicos y la integración de los resultados obtenidos dentro de esquemas de mantenimiento predictivo.

Adicionalmente, su aumento rango de medición, que puede establecer valores superiores a 1200 °C, posibilita la examinación térmica de transformadores, barras colectoras, interruptores y otros elementos presentes en subestaciones eléctricas bajo condiciones reales de operación. Todos estos detalles son imprescindibles para aplicar adecuadamente la técnica de cámara termografía en la detección de irregularidades o del estado del equipo, lo cual permite tomar medidas antes de que estas se conviertan en fallas capaces de causar paradas imprevistas y/o accidentes.

2.1.3. EMISIVIDAD Y FACTORES QUE AFECTAN LA MEDICIÓN TÉRMICA

La emisividad pertenece a una particularidad inherente de los materiales que enumera su capacidad para pronunciar energía térmica en la visión infrarroja, en balance con el comportamiento de un cuerpo negro ideal. En el caso de los dispositivos eléctricos, este parámetro no se establece un valor establecido, ya que se ve influenciado por diversos factores, tales como la naturaleza del material, las condiciones del acabado superficial, el nivel de oxidación y la acumulación de contaminantes a lo largo del tiempo de operación.

El análisis de la relación entre datos subjetivos y objetivos hace posible desarrollar una fórmula que muestra la disconformidad térmica a partir de factores locales. La temperatura de confort para los edificios que se han analizado es de $23,3$ °C y el porcentaje más bajo de personas disconformes con esa temperatura es del 7%. Términos clave: trabajo de campo, índice de insatisfacción, temperatura neutra, sensación térmica, gusto térmico., el ángulo de observación y la presencia de radiación reflejada proveniente de superficies cercanas [9].

2.1.4. ANOMALÍAS TÉRMICAS EN EQUIPOS ELÉCTRICOS

En los sistemas eléctricos, las anomalías térmicas se manifiestan como elevaciones de temperatura que se apartan del comportamiento esperado durante la operación normal de los equipos. Este fenómeno suele estar asociado al aumento de la resistencia eléctrica en determinados elementos, lo que incrementa las pérdidas por efecto Joule y produce una generación adicional de calor.

Emplear cámaras termográficas para estimar las temperaturas de componentes esenciales, como transformadores, cables e interruptores, y comparar estas observaciones con las normas ejecutivas recomendadas. Se transportaron a cabo balances numéricas para emparejar irregularidades térmicas y se exploraron las mediciones de temperatura adquiridas en el método cuantitativo. Cuando estas circunstancias no son examinadas de manera oportuna, pueden evolucionar hacia eventos de mayor dificultad, tales como cortocircuitos, incendios o daños irreversibles en los dispositivos eléctricos [10].

La clasificación de las anomalías térmicas en función de su nivel de severidad compone un utensilio clave para la administración del mantenimiento, ya que posibilita definir prioridades de intervención, mejorar el uso de los recursos existentes y reducir la posibilidad de paradas imprevistas en el suministro eléctrico.

Es evidenciable que la **Tabla 2**, vincula que la mayoría de los registros de temperatura es el transformador de potencia, que constituye el porcentaje de factor de precipitación.

Prioridad	Equipo De Subestación Residencial	Valor Delta T °C	Factor De Precipitación.
1	Transformador De Poder	19,7	32%
2	Cuchillas De Entrada Reconectador 1	13,6	22%
3	Cuchillas De Salida Reconectador 3	10,4	17%
4	Seccionador De 69 Kv	6,4	10%
5	Pararrayos De 69 Kv	6,1	10%
6	GCB	5,6	9%

Tabla 2. De Incidencias En Altas Temperatura Por Equipos De Subestación

2.1.5. SUBESTACIONES ELÉCTRICAS

Las subestaciones eléctricas constituyen infraestructuras fundamentales del método eléctrico de potencia, debido a que permiten adecuar los niveles de tensión, ejecutar operaciones de conexión y desconexión, y brindar protección a los equipos frente a eventuales fallas eléctricas. El correcto desempeño de estas instalaciones resulta esencial para certificar la continuación del servicio, así como la disposición y proteger en el sistema de energía eléctrica. los sistemas eléctricos, las anomalías térmicas [11].

2.1.6. ESQUEMA UNIFILAR DE UNA SUBESTACIÓN ELÉCTRICA

El esquema unifilar, que muestra la disposición de los componentes eléctricos de cada circuito, es el medio expresa la configuración eléctrica de una subestación.

La figura 1 ilustra el esquema representativo de la subestación transformadora de 69 kV, que comprende una bahía de transformación y otra como línea de ingreso a la barra de 69 kV con rasgos simples [12].




Figura 1. Diagrama De Sistema Unifilar

Fuente: Autores

Como se puede apreciar en el esquema se encuentran los elementos fundamentales, tales como el a) seccionador principal de 69 kV con su método de puesta a tierra, b) pararrayos de distribución a nivel de 69 kV, c) Interruptor de 69 kV GCB, d) Transformador de poder, e) Seccionador fundamental de 13.8 kV, y f) los reconectores de media tensión.

2.2. CLASIFICACIÓN DE LAS SUBESTACIONES ELÉCTRICAS

Las subestaciones eléctricas pueden estar consideradas de acuerdo con la función que cumplen dentro del sistema eléctrico en subestaciones elevadoras, reductoras, de maniobra y de distribución. Las subestaciones elevadoras tienen como objetivo incrementar el nivel de tensión para facilitar la transmisión del suministro eléctrico a grandes distancias, mientras que las subestaciones reductoras disminuyen la tensión para su posterior suministro a los usuarios finales. En cambio, las subestaciones de maniobra se destinan a la interconexión y seccionamiento de líneas, sin realizar procesos de transformación de tensión. El estudio se enfocará en las subestaciones reductoras las cuales tienen un papel importante en el sector de comercialización del suministro eléctrico [13].

2.2.1. COMPONENTES DE UNA SUBESTACIÓN ELÉCTRICA

Como se pudo observar en la **Figura 1**, los elementos que conforman una subestación eléctrica cumplen funciones particulares dentro del sistema de potencia, y su operación adecuada resulta fundamental para certificar la continuidad y la protección del suministro de energía eléctrica. Entre los equipos de mayor relevancia, tanto por su importancia operativa como por su susceptibilidad a presentar fallas de origen térmico, se encuentran el interruptor de potencia de 69 kV tipo GCB, el transformador de potencia y el seccionador principal de media tensión. Estos elementos en conjunto con los reconectores juegan un papel importante en las subestaciones por estar dentro del mayor número de operaciones aparte de sus altos costos en especial el transformador de potencia.

Este aparato lleva a cabo el análisis de un grupo de imágenes adquiridas en la subestación objeto de estudio, utilizando la técnica cualitativa de termografía comparativa. La evaluación se centra en los bushings de alta y baja tensión del transformador de potencia, además de los que pertenecen al ingreso y egreso del disyuntor de potencia (GCB), así como otros equipos que tienen gran relevancia por sus costos operativos y su funcionamiento [14].

2.2.2. INTERRUPTOR DE POTENCIA DE 69 KV TIPO GCB

El interruptor de potencia de 69 kV, comúnmente del tipo GCB (Gas Circuit Breaker), es un dispositivo destinado a la maniobra de circuitos eléctricos tanto en condiciones normales de operación como en escenarios anómalos, donde se requiere la interrupción de corrientes de falla. Este tipo de interruptor emplea gas SF₆ como medio de extinción del arco eléctrico, debido a sus destacadas propiedades dieléctricas y su elevada capacidad para disipar el calor generado durante la interrupción [15].

Desde la perspectiva del análisis termográfico, los interruptores GCB se consideran equipos de alta criticidad, ya que presentan diversos puntos susceptibles a incrementos anormales de temperatura, entre ellos los contactos principales, las conexiones a barras, los terminales, los sistemas mecánicos de accionamiento y las cámaras de interrupción. La presencia de sobrecalentamientos en estas zonas puede ser indicativa de desgaste en los contactos, disminución de la presión del gas, deficiencias en las conexiones eléctricas o fallas de tipo mecánico, condiciones que podrían comprometer la capacidad de interrupción del equipo.

La ejecución de exámenes termográficos de modo habitual en interruptores de 69 kV permite identificar este tipo de anomalías en etapas tempranas, reduciendo la probabilidad de fallas severas y contribuyendo a mejorar la confiabilidad operativa de la subestación eléctrica.

En la **Figura 2**, el interruptor general que se usan en las subestaciones de la ciudad de Guayaquil, es un interruptor categorizado como tanque muerto:



Figura 2. *Interrupción de Potencia*

Fuente: *Autores*

En la **Figura 3**, al realizar una imagen térmica del equipo, se pueden ver los niveles de temperatura de calentamiento en las zonas calientes.

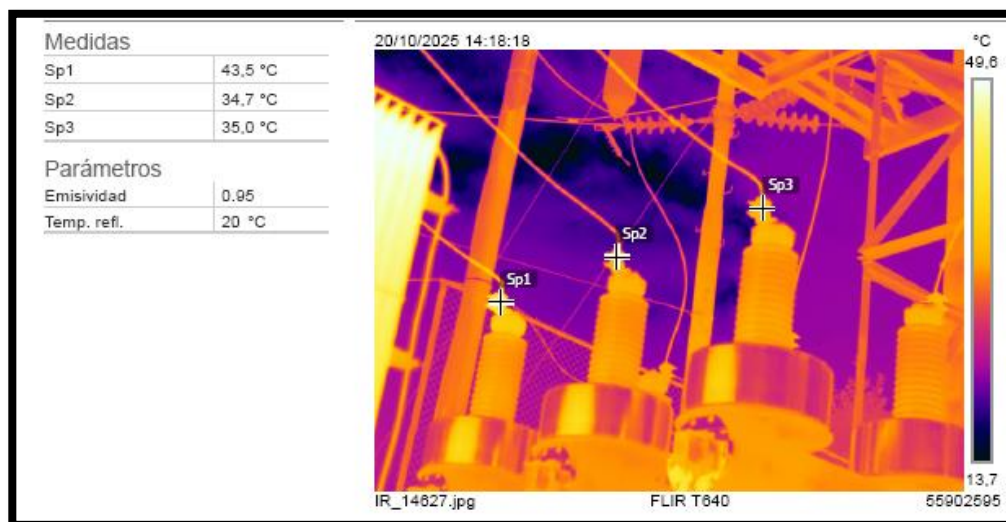


Figura 3. *Termografía de Interrupción de Potencia*

Fuente: *Autores*

De acuerdo a la norma los niveles de temperatura en uno de los terminales (SP1) se encuentran con una alteración de sus condiciones normales y siguiendo la norma anteriormente mencionada posee un delta ($D= 10^{\circ}\text{C}$). Me lleva a reconocer que tiene una criticidad leve.

2.2.3. TRANSFORMADOR DE PODER

El transformador de potencia constituye uno de los activos más relevantes y de mayor costo dentro de una subestación eléctrica. Su función esencial es adecuar los rangos de tensión con la conclusión de garantizar una transmisión y colocación eficiente de la energía eléctrica. Debido a su complejidad constructiva y a su importancia estratégica dentro del sistema de potencia, una falla en este equipo puede ocasionar interrupciones prolongadas del servicio, así como elevados costos asociados a su reparación o sustitución.

La generación de calor en un transformador de potencia se origina principalmente por las pérdidas en el núcleo magnético, las mermas resistivas por efecto Joule en los devanados y las pérdidas presentes en conexiones y bornes. Mediante la aplicación de la termografía infrarroja es posible evaluar la distribución térmica en componentes como el tanque principal, los radiadores, las conexiones de alta y media tensión, los cambiadores de tomas y los bushings [16].

La presencia de anomalías térmicas en transformadores puede estar relacionada con condiciones de sobrecarga, degradación del aislamiento, deficiencias en el sistema de enfriamiento o problemas en las conexiones eléctricas. La identificación temprana de estas irregularidades a través de inspecciones termográficas resulta fundamental para prevenir fallas de mayor magnitud y contribuir al alargamiento de la vida útil del transformador.

La **Figura 4**, el transformador de poder que se usan en las subestaciones de la ciudad de Guayaquil, es un transformador categorizado como tanque sellado o conocido como tanque presión constante:



Figura 4. Transformador de Potencia

Fuente: Autores

Se estableció una imagen térmica del equipo que es posible observar los niveles de temperatura, que se encuentra nuestro transformador como se puede ver en la **Figura 5**.



Figura 5. Termografía de Puntos Calientes

Fuente: Autores

En la **Figura 6**, se observa Sp1 en un grado de calentura de 54.2°C en la cual podemos observar que se encuentra en un nivel moderado de temperatura.



Figura 6. Transformador de Potencia

Fuente: Autores

De acuerdo a la norma los niveles de temperatura en uno de los terminales (SP3 y SP1) se encuentran con una alteración de sus condiciones normales y siguiendo la norma anteriormente mencionada posee un delta ($D= 10^{\circ}\text{C}$). Nos llevaría a reconocer que tiene una criticidad leve.

2.2.4. SECCIONADOR PRINCIPAL DE MEDIA TENSIÓN

El seccionador principal de media tensión es un dispositivo de maniobra cuya finalidad es proporcionar el aislamiento eléctrico de determinadas secciones de la subestación, permitiendo la ejecución de trabajos de mantenimiento en condiciones seguras. A diferencia del interruptor de potencia, este dispositivo no está concebido para interrumpir corrientes de carga, por lo que su operación se desarrolla únicamente cuando el circuito se estabiliza sin corriente o con niveles muy bajos.

El propósito fundamental de estos dispositivos es separar partes de circuitos de una forma visible. Los circuitos que se necesiten interrumpir tienen que estar sin corriente, es decir, el

seccionador tiene que funcionar en vacío. No obstante, tiene que ser capaz de soportar las corrientes nominales, las sobrecargas y las corrientes de cortocircuito a lo largo de un tiempo específico. Así, este aparato asegurará que las partes aisladas del circuito se encuentren libres de tensión y sean tocables por los trabajadores sin peligro. La fabricación y el diseño de los seccionadores están sujetos a las normas ANSI C29.8 y C29.9 o a las normas IEC 60129 y 60273, además de cumplir con la IEC 60694 en términos de valores nominales y pruebas (tensión resistida a impulso y 60 Hz).

La ejecución de la termografía infrarroja en seccionadores de media tensión permite identificar de manera temprana contactos defectuosos y conexiones en mal estado. La corrección oportuna de estas anomalías contribuye a evitar fallas de mayor gravedad, la aparición de arcos eléctricos y posibles daños en equipos adyacentes dentro de la subestación., se presenta la **Figura 7**, el seccionador principal de 13.8 kV que se usan en las subestaciones de la ciudad de Guayaquil, es un transformador categorizado como seccionador de aire de media tensión [17].



Figura 7. Seccionador Principal de Media Tensión

Fuente: Autores

En la **Figura 8**, se observa la apariencia de puntos calientes localizados en conexiones del sistema eléctrico, con temperaturas máximas cercanas a 49 °C. Estas elevaciones térmicas indican posibles problemas en las conexiones, sobrecargas o desequilibrios operativos. El estudio confirma que la termografía infrarroja es una herramienta de diagnóstico preventiva efectiva para identificar fallos en fases iniciales y reducir los peligros operativos.




Figura 8. Termografía Seccionador Principal de Media Tensión

Fuente: Autores

De acuerdo con la norma los niveles de temperatura en uno de los terminales (SP1) se encuentran con una alteración de sus condiciones normales y siguiendo la norma anteriormente mencionada posee un delta ($D= 10^{\circ}\text{C}$). Nos llevaría a reconocer que tiene una criticidad leve.

2.2.5. RECONECTADORES DE MEDIA TENSIÓN

En la **Figura 9**, es un equipo de operación automática destinados a la protección de las líneas de distribución y de los propios equipos del sistema. Cuentan con un sistema de intervención electrónico y un conductor ejemplo plus, mediante el cual se supervisan las corrientes asociadas a condiciones de problema. De manera principal, el reconectador tiene como

función principal la interrupción del circuito cuando se presenta una anomalía. Ante la aparición de una falla provocada por una sobre corriente, el equipo actúa abriendo el circuito y posteriormente realiza el cierre de forma automática. En los casos en que la sobre corriente sea de carácter transitorio, el proceso de reconexión permite restablecer el suministro eléctrico. Sin embargo, cuando la falla persiste, el reconectador efectúa un número previamente definido de aperturas y cierres antes de quedar en estado de bloqueo. En los reconectores trifásicos de los tipos VWE y VWVE, las tres fases operan de manera conjunta, abriéndose, cerrándose y bloqueándose de forma simultánea [18].



Figura 9. Reconectador de Media Tensión

Fuente: Autores

En la **Figura 10**, se muestra una conducta térmica relativamente estable entre los aisladores y conexiones del equipo, con una temperatura aproximada de 42,2 °C. No se observan gradientes térmicos severos, lo que se establece una operación normal sin indicios claros de sobrecalentamiento crítico.

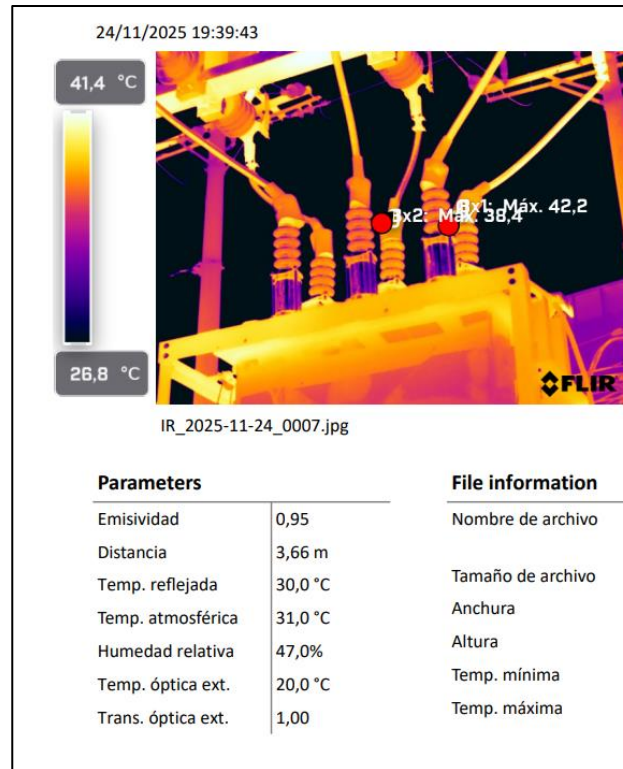


Figura 10. Termografía de Reconector de Media Tensión

Fuente: Autores

De acuerdo con la norma los niveles de temperatura en uno de los terminales (SP1) se encuentran con una alteración de sus condiciones normales y siguiendo la norma anteriormente mencionada posee un delta ($D= 10^{\circ}\text{C}$). Nos llevaría a reconocer que tiene una criticidad leve.

2.2.6. MONITOREO TÉRMICO EN SUBESTACIONES

La búsqueda del comportamiento térmico de los dispositivos permite igualar desviaciones en las condiciones normales de maniobra antes de que estas evolucionen hacia problemas de mayor severidad. En este contexto, la gestión de la termografía infrarroja en las subestaciones eléctricas permite detectar sobrecalentamientos con antelación, lo que ayuda a aumentar la confiabilidad del sistema eléctrico de forma explicativa.

2.2.7. MANTENIMIENTO PREDICTIVO EN SUBESTACIONES ELÉCTRICA

El mantenimiento predictivo se basa en la examinación continua o programada de las condiciones de operación de los dispositivos, mediante el estudio de técnicas de monitoreo que permiten prever la aparición de problemas antes de que éstas se plasmen. A diferencia de los enfoques correctivo y preventivo, esta idea contribuye a una principal gestión de los recursos y a la rebaja de los períodos de indisponibilidad de los equipos [19].

2.2.8. TÉCNICAS DE MANTENIMIENTO PREDICTIVO

En las subestaciones eléctricas se emplean diversas técnicas de mantenimiento predictivo, entre las cuales destacan la termografía infrarroja, el análisis de vibraciones, la medición de descargas parciales y el análisis de aceites dieléctricos. Dentro de este conjunto de métodos, la termografía infrarroja sobresale por su carácter no intrusivo y por la posibilidad de identificar anomalías térmicas en equipos energizados y en tiempo real. En nuestro estudio realizaremos un análisis de la técnica infrarroja adaptando un modelo de inteligencia artificial aplicado [20].

2.2.9. VENTAJAS DEL MANTENIMIENTO PREDICTIVO

La aplicación del mantenimiento predictivo ayuda a reducir el costo operativo, así como a reducir las interrupciones no planeadas y extender la duración de los dispositivos. Además, este procedimiento perfeccionamiento las condiciones de proteger el equipo técnico y permite que la planificación de las tareas de mantenimiento sea más eficaz y apropiada.

2.2.10. LIMITACIONES DEL ENFOQUE TRADICIONAL

El mantenimiento predictivo convencional tiene restricciones a pesar de sus beneficios, entre las cuales sobresale la dependencia y aumento del análisis hecho por la persona especializado y el aumento en la cantidad de datos obtenidos. Estas circunstancias logran obstaculizar la interpretación adecuada de la información sobre los datos hallados, lo cual ha impulsado el uso de herramientas apoyadas por inteligencia artificial que son capaces de resolver los datos con más eficiencia y de manera automatizada.

2.2.11. INTELIGENCIA ARTIFICIAL Y APRENDIZAJE AUTOMÁTICO

La inteligencia artificial es un método de la informática orientada al desarrollo de sistemas que pueden ejecutar tareas asociadas al razonamiento humano, tales como la identificación de patrones, el aprendizaje basado en datos y la toma independiente de decisiones.

2.1.12. APRENDIZAJE SUPERVISADO Y NO SUPERVISADO

La instrucción supervisada se establece en el empleo de conjuntos de información previamente etiquetados para fortalecer modelos capaces de desarrollar tareas de clasificación o predicción. En contraste, la enseñanza no supervisada se orienta a la información de estructuras o patrones presentes en datos que no disponen de etiquetas. En aplicaciones relacionadas con el estudio de imágenes termográficas, el estudio supervisado constituye el enfoque más comúnmente utilizado.

Mantenimiento Predictivo En Subestaciones Eléctrica

En la **Figura 11**, se realiza trabajos de mantenimiento en una estructura de transmisión eléctrica, donde se observan aisladores, conductores y personal interviniendo directamente sobre el sistema.



Figura 11. Mantenimiento Predictivo En Subestaciones Eléctrica

Fuente: Autores

2.3. REGULACIÓN ARCONEL 004/01, NIVEL DE VOLTAJE Y CALIDAD DEL PRODUCTO

La calidad del producto está relacionada con la capacidad del sistema eléctrico para suministrar energía, cumpliendo con los estándares necesarios. Esto significa que el voltaje debe ser el correcto, las variaciones deben ser mínimas y el factor de potencia tiene que estar en un rango apropiado. El distribuidor tiene la obligación de medir estas dimensiones de forma periódica, analizar los datos y detectar problemas que puedan afectar a los usuarios [21]. Un distribuidor no satisface los niveles de voltaje fijados si, durante una semana consecutiva, se observa que el 5 % o más del tiempo el voltaje entregado excede los límites establecidos.

En la **Tabla 3**, los niveles de tensión y también los niveles de periodos establecido para cada nivel de tensión.

Tensión	Período 1	Período 2
Alto Tensión	$\pm 8 \%$	$\pm 6 \%$
Media Tensión	$\pm 12\%$	$\pm 10\%$
Baja Tensión Urbano	$\pm 12 \%$	$\pm 10\%$
Baja Tensión Rural	$\pm 15\%$	$\pm 12\%$

Tabla 3. Límites de tensiones en porcentajes %

Las siguientes **Tabla 4**, muestran las simbologías que indican una actualización de la regulación 004/01, la cual establece límites e índices de calidad del producto para diversos clientes favorecidos por la compañía distribuidora Cnel.

Unidades	Niveles Voltaje
AV	Alto Voltaje
BV	Bajo Voltaje
MV	Medio Voltaje
V_n	Voltaje Nominal
V_s	Voltaje proporcionado en un momento específico

Tabla 4. Abreviaturas En La Categorización Del Voltaje

La **Tabla 5**, presenta los valores correctos con sus límites expresados en términos de voltaje nominal.

Niveles De Tensión	
Baja tensión	$0,6 \text{ kV} = <$
Media tensión	$\geq 0,6 \text{ kV}, \leq 40 \text{ kV}$
Alta tensión Grupo No.1	$\geq 40 \text{ kV}, \leq 138 \text{ kV}$
Alta tensión Grupo No.2	$\geq 138 \text{ kV}$

Tabla 5. Niveles de Voltaje

2.3.1. APRENDIZAJE PROFUNDO

El estudio profundo es una subdivisión de la enseñanza automático que se va utilizar redes neuronales con varias capas ocultas. Este tipo de arquitecturas proporciona la representación de relaciones complicadas en los datos y ha mostrado un desempeño excelente en tareas que tienen que ver con el procesamiento de imágenes y señales.

2.3.2. VENTAJAS DE LA INTELIGENCIA ARTIFICIAL EN SISTEMAS ELÉCTRICOS

La incorporación de métodos de inteligencia artificial en los sistemas de energía eléctrica proporciona el procesamiento de grandes cantidades de información encontrada, disminuye la incidencia de errores asociados al análisis humano que aumenta la exactitud de los diagnósticos. De esta manera, se consolida como una herramienta principal para la modernización y optimización de las estrategias de mantenimiento eléctrico.

2.3.3. REDES NEURONALES CONVOLUCIONALES (CNN)

Las redes neuronales convolucionales son una estructura específica del estudio profundo que se encarga de analizar y procesar imágenes. Se determina que el estudio exhaustivo permitirá la adquisición y análisis de imágenes, además de la capacidad para tomar decisiones. La primera circunstancia de esta revisión ofrece una descripción general acerca del funcionamiento de las redes neuronales convolucionales, sus principios básicos y los enfoques contemporáneos en la educación médica centrada en imágenes diagnósticas [22].

La ejecución de la termografía eléctrica, las redes neuronales convolucionales (CNN) facilitan la identificación automática de patrones térmicos asociados a condiciones anómalas, permitiendo la clasificación de imágenes en empleo del nivel de severidad en los problemas con un alto grado de precisión.

2.3.4. APLICACIÓN DE INTELIGENCIA ARTIFICIAL EN TERMOGRAFÍA ELÉCTRICA

La integración de técnicas de inteligencia artificial con la termografía infrarroja posibilita la utilización y automatización del procesamiento de imágenes térmicas y transformar grandes volúmenes de datos en información relevante que respalde la toma de decisiones.

2.3.5 AUTOMATIZACIÓN DEL DIAGNÓSTICO TÉRMICO

Los estudios basados en inteligencia artificial facilitan la identificación automática de puntos calientes y anomalías térmicas, reduciendo la necesidad de análisis manual y reparando la uniformidad y seguridad de los diagnósticos.

2.3.6. CLASIFICACIÓN DE SEVERIDAD TÉRMICA

La aplicación de algoritmos del estudio profundo es posible catalogar las anomalías térmicas de acuerdo con su grado de complicidad de severidad, lo que posibilitan una priorización más objetiva y eficiente de las acciones de mantenimiento [23].

2.3.7. APOYO A LA TOMA DE DECISIONES EN MANTENIMIENTO

Los sistemas de termografía eléctrica apoyados en inteligencia artificial proporcionan información confiable y oportuna al personal de mantenimiento, lo que facilita la planificación de las intervenciones y contribuye a reducir el riesgo de fallas imprevistas en las subestaciones eléctricas.

2.3.8. PROCESAMIENTO DIGITAL DE IMÁGENES TÉRMICAS

El avance de los equipos computacionales ha autorizado en la complementación de la inspección termográfica tradicional con tácticas de procesamiento digital de imágenes. Mediante lenguajes de programación como Python y bibliotecas especializadas, es posible

establecer imágenes térmicas para eliminar información cuantitativa, como temperaturas máximas, mínimas, promedios y diferencias térmicas (ΔT).

Plataformas como Google Colab proporcionan este tipo de análisis al ofrecer un entorno de programación accesible desde el navegador, no se requiere instalaciones locales. Esto permite al personal técnico y a los investigadores procesar grandes volúmenes de imágenes térmicas, generar gráficos, mapas de calor e incluso exportar resultados para su análisis posterior o documentación técnica [24].

2.3.9. GOOGLE COLAB

Google Colab es una aplicación de computación en la nube que posibilita redactar programación y poner en marcha código en Python directamente desde el navegador web, sin requerir la instalación previa de un software determinado en la computadora del usuario. Esta cualidad se consolida en una herramienta eficaz y asequible para el análisis y desarrollo de imágenes termográficas, sobre todo en aplicaciones de diagnóstico y mantenimiento de sistemas eléctricos. Google Colab posibilita la evaluación y el procesamiento de imágenes térmicas capturadas por cámaras especializadas, como por la termografía infrarroja. Ejemplo las de tecnología FLIR, en el ámbito de la termografía infrarroja. Así, en la **Figura 12**, utilizamos Google Colab se establece como un instrumento de soporte en la evaluación termográfica, al mezclar la facilidad de acceso, el poder de procesamiento y la adaptabilidad en el manejo de datos térmicos [25].

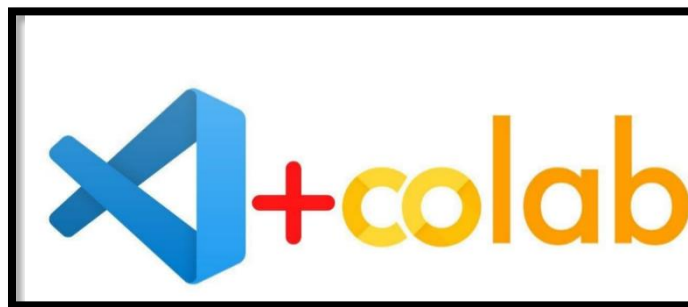


Figura 12. Google Colab

CAPITULO III

3.1. DESCRIPCIÓN DEL CASO DE ESTUDIO

3.2. METODOLOGIA

En la **Figura 13**, se analiza un proceso que comienza con la captura de la foto térmica por una persona y su descarga desde la nube para transformar la imagen en datos precisos de temperatura. Luego, mediante inteligencia artificial y sobre las redes neuronales convolucionales (CNN), el sistema analiza los puntos calientes y el nivel de riesgo para entregar un diagnóstico automático que indica la urgencia de la reparación.

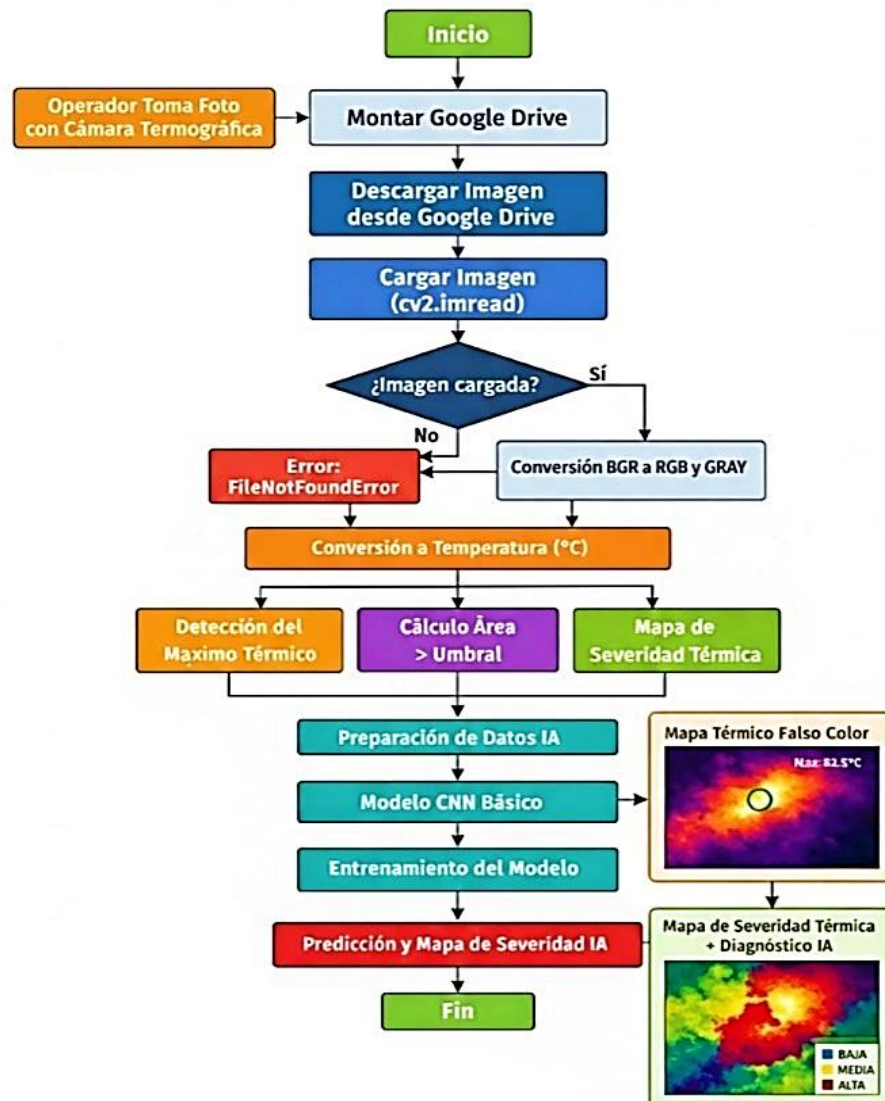


Figura 13. Diagrama De Flujo del Procedimiento del Trabajo

3.2.1. PROTOTIPO PROPUESTO

La **Figura 14**, muestra de forma clara el proceso seguido para realizar el análisis termográfico de equipos eléctricos. En primer lugar, se utiliza una cámara termográfica portátil para capturar imágenes infrarrojas directamente en campo, bajo condiciones reales de operación. Estas imágenes térmicas se complementan con fotografías en el espectro visible, lo que permite identificar con mayor precisión los componentes analizados. Posteriormente, se generan mapas térmicos en escala de color que ayudan a reconocer fácilmente variaciones de temperatura y puntos calientes. El procesamiento de la información se lleva a cabo mediante Python, apoyado en librerías como OpenCV y Matplotlib. A partir de ello, se aplican algoritmos de análisis y clasificación térmica para detectar posibles anomalías. Finalmente, los resultados se presentan mediante valores de temperatura y representaciones gráficas que facilitan su interpretación.

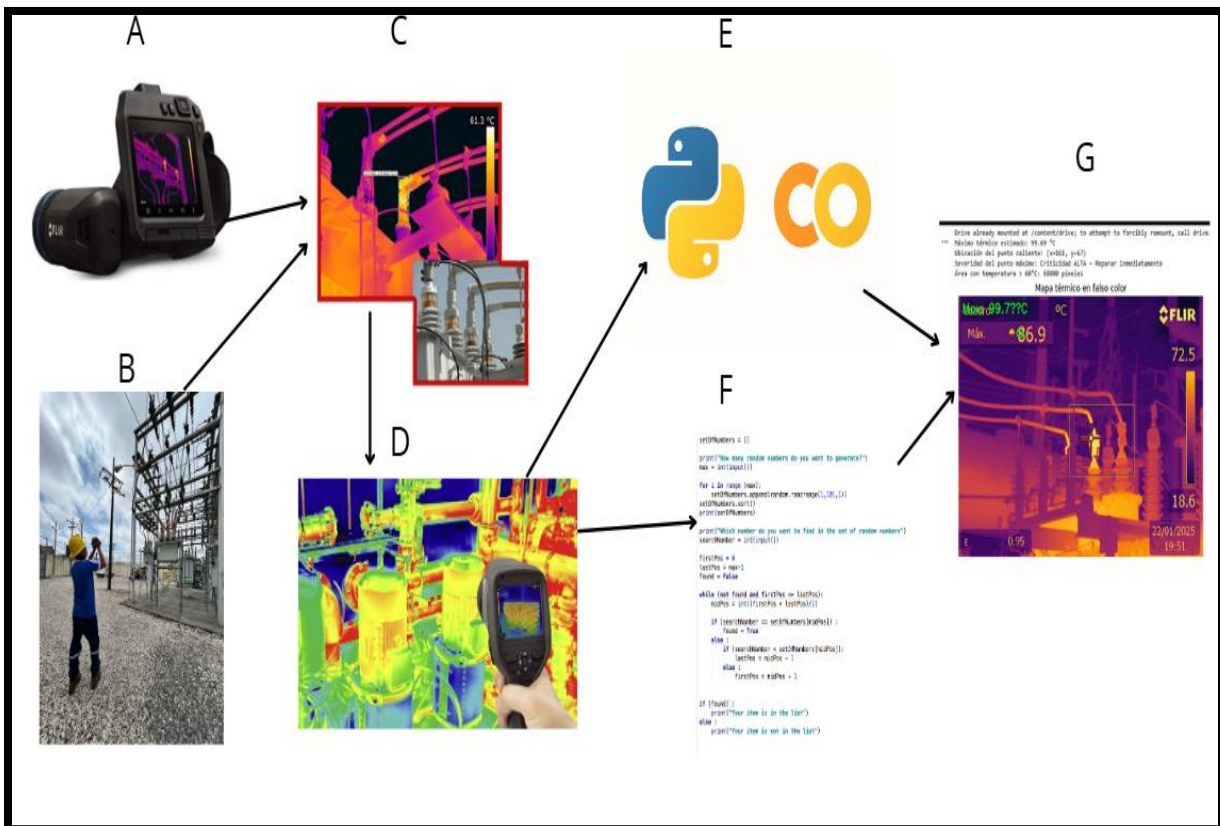


Figura 14. Prototipo Propuesto

Fuente: Autores

- A. Cámara Termográfica
- B. Operación De La Cámara Termográfica
- C. Imágenes De Puntos Calientes En Subestación
- D. Imágenes De Punto Calientes En Equipos De Protecciones
- E. Programa Colab
- F. Lenguaje De Python
- G. Resultado De La Simulación Con El Programa De Colab

3.2.2. ENFOQUE METODOLÓGICO

Se presente como una investigación es cuantitativo–experimental, orientado al análisis numérico de información térmica obtenida mediante termografía infrarroja, procesamiento digital de imágenes y modelos de aprendizaje profundo. Este enfoque permite transformar datos visuales en información térmica objetiva, analizar patrones de comportamiento térmico en equipos eléctricos de subestaciones y evaluar el desempeño de un sistema automatizado de diagnóstico basado en inteligencia artificial.

La metodología integra adquisición de datos, procesamiento térmico, visualización, clasificación normativa, entrenamiento de modelos de IA y validación de resultados, con el fin de mejorar la confiabilidad operativa y apoyar la toma de decisiones en mantenimiento predictivo.

3.2.3. RECOPIACIÓN DE DATOS TERMOGRÁFICOS DE EQUIPOS ELÉCTRICOS

Dentro de la recopilación de información se procederá a exportar las imágenes desde el software de la cámara termo gráfica de acuerdo con la ,**Figura 15**.




Figura 15. Software FLIR

Fuente: Autores

Luego una vez exportada se seleccionarán las de mayor incidencia de daños de acuerdo al nivel de temperatura de acuerdo con la **Figura 16**.

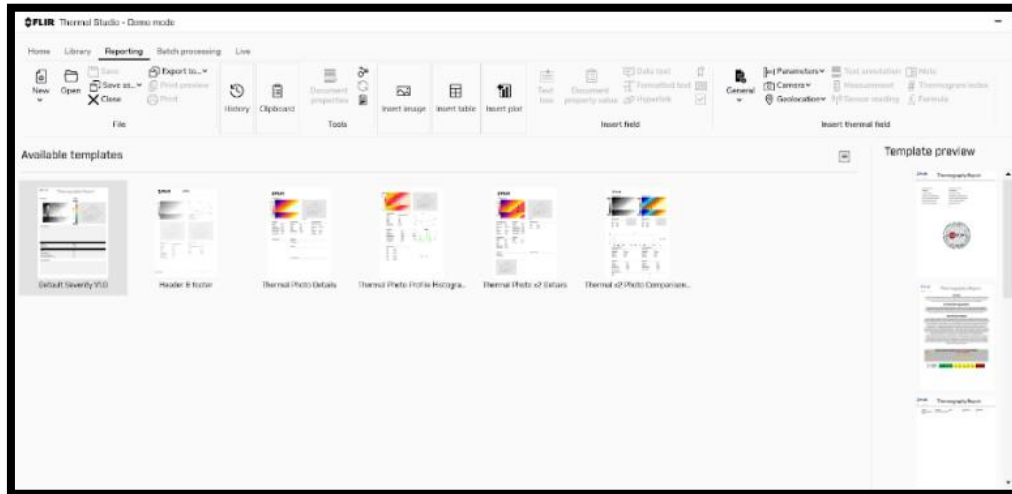


Figura 16. Importación De Imágenes Software FLIR

Fuente: Autores

Una vez extraída las imágenes de cada elemento de mayor incidencia de temperatura procederemos a evaluar los índices de acuerdo con la tabla NETA.

En la siguiente **Figura 17**, se exponen todos los equipos de la subestación de mayor incidencia de temperatura. Se procederá también a codificarla según sea el caso




Figura 17. Imágenes Termográficas De Equipos De La Subestación

Fuente: Autores

En la **Figura 18**, se muestra el caso de un transformador de poder con alto grado de temperatura en un bushing de baja.



Figura 18. Transformador De Poder Con Alta Temperatura En Terminales De Bushing

Fuente: Autores

En esta etapa se realiza la adquisición de imágenes termográficas de equipos críticos de subestaciones eléctricas, tales como transformadores de potencia, conexiones, aisladores y barras conductoras, utilizando cámaras infrarrojas calibradas.

Las imágenes obtenidas representan la distribución espacial de radiación térmica, la cual está directamente relacionada con el estado operativo del equipo. Estos datos constituyen la materia prima del estudio y deben cumplir criterios de calidad, tales como:

- Correcta distancia de captura
- Emisividad adecuada del material
- Condiciones ambientales controladas

Las imágenes recopiladas son almacenadas en formatos digitales compatibles para su posterior análisis computacional.

3.2.4. IMPORTACIÓN Y FUNCIÓN DE LAS LIBRERÍAS UTILIZADAS

En esta etapa se procederá a usar el software COLAB auspiciado por Google, el software se basa en el lenguaje de programación de Python, a continuación, se observa el entorno de interfaz de COLAB de acuerdo con la **Figura 19**.



Figura 19. Colab De Google

Fuente: Autores

La selección y organización de las librerías empleadas en el desarrollo del sistema de diagnóstico termográfico responden a criterios metodológicos orientados al procesamiento de imágenes, análisis numérico, visualización de resultados y entrenamiento de modelos de inteligencia artificial. A continuación, se describen las librerías utilizadas, siguiendo el orden establecido en el listado.

3.2.4.1. OPENCV (CV2)

La librería OpenCV se utiliza como instrumento fundamental en el proceso digital de imágenes termográficas. Su utilidad metodológica consiste en leer, convertir y manejar imágenes; es decir, en transformar los datos visuales obtenidos a través de la cámara infrarroja en estructuras de la información que pueden ser analizadas.

OpenCV hace más sencillo la transformación entre diferentes espacios de color, la normalización de intensidades y la creación de mapas visuales que se agrega como

fundamento para el análisis térmico posterior. Su uso garantiza un tratamiento eficiente y preciso de las imágenes, indispensable para la confiabilidad del diagnóstico [26].

3.2.4.2. NUMPY (NUMPY)

NumPy se monopoliza para el uso y el proceso de datos numéricos, especialmente matrices que simbolizan mapas térmicos y distribuciones de temperatura. Desde una orientación metodológica, esta librería nos permite analizar cálculos matemáticos, estadísticos y operaciones vectorizadas sobre grandes informaciones de datos térmicos.

Gracias a NumPy, es posible asemejar valores extremos de temperatura, analizar el estudio de áreas críticas y estructurar los datos de entrada y salida requeridos para la capacitación del modelo de inteligencia artificial.

3.2.4.3. MATPLOTLIB (MATPLOTLIB.PYPLOT)

La incorporación de representaciones gráficas en los resultados térmicos se fundamenta en el uso de la librería Matplotlib, la cual, desde una perspectiva metodológica, permite la visualización precisa y eficiente de mapas térmicos en escala de color, mapas de intensidad y resultados provenientes de procesos de clasificación de datos. La aplicación de esta herramienta facilita la interpretación del comportamiento térmico de los equipos eléctricos, fortaleciendo la validación de los resultados obtenidos y optimizando la comunicación clara y efectiva de los hallazgos dentro del estudio [27].

3.2.4.4. TENSORFLOW (TENSORFLOW)

TensorFlow compone la plataforma base para el progreso y preparación de modelos de enseñanza profundo. Desde mi punto de observación metodológico, esta librería suministra la infraestructura necesaria para organizar sistemas inteligentes capaces de formarse patrones complicados a partir de datos térmicos.

Su uso permite realizar procesos de entrenamiento, optimización y desarrollo del modelo, afirmando la reproducibilidad y escalabilidad del sistema de diagnóstico propuesto [28].

3.2.4.5. KERAS – MODELOS

La interfaz Keras, que es parte de TensorFlow, se emplea para establecer el modelo de una red neuronal de forma ordenada. La metodología de esta biblioteca se encamina en simplificar el progreso de arquitecturas de la enseñanza profundo, haciéndolo modular y organizado.

Este modelo secuencial posibilita la creación de una serie lógica de capas, que se extiende desde la introducción de imágenes térmicas hasta la entrega de clasificaciones de gravedad, lo que contribuye a esclarecer el diseño del sistema [29].

3.3. PRE PROCESAMIENTO Y CONVERSIÓN DE INFORMACIÓN VISUAL A DATOS TÉRMICOS

Una vez extraída las imágenes, se emplea un asunto de preprocesamiento, cuyo objetivo es tomar medidas para la información para el estudio térmico y el entrenamiento del modelo de inteligencia artificial.

Esta causa contiene la conversión de la información visual a escala de intensidad, consintiendo corresponder a los rangos de brillo de cada píxel con valores de temperatura estimados. Mediante esta ecuación se obtiene un mapa térmico matricial, donde cada elemento representa un valor térmico cuantificable en grados Celsius.

La conversión del nivel de gris de una imagen térmica a temperatura se realiza mediante una relación lineal, expresada como:

$$T(x, y) = \frac{T_{min} + G(x, y)}{255} * (T_{max} - T_{min}) \quad (1)$$

Donde:

T(x,y): temperatura estimada en el píxel ubicado en la posición, expresada en grados Celsius (°C) o Kelvin (K).

Tmin: temperatura mínima correspondiente al nivel de gris 0 de la imagen térmica, expresada grados Celsius (°C).

Tmax: temperatura máxima correspondiente al nivel de gris 255 de la imagen térmica grados Celsius (°C).

G(x,y): valor de intensidad en escala de grises del píxel con un oscila entre 0 y 255.

255: valor máximo posible en una imagen digital de 8 bits.

Esta etapa es fundamental, ya que transforma imágenes cualitativas en datos numéricos confiables, permitiendo análisis estadísticos, comparaciones normativas y evaluación automática de condiciones térmicas, la imagen de píxeles en valores de temperatura y muestra un mapa en falso color para ver rápidamente las zonas calientes.

3.3.1. IDENTIFICACIÓN DE PUNTOS CRÍTICOS Y PATRONES TÉRMICOS

Con los datos térmicos procesados, se procede a la identificación de puntos calientes, entendidos como zonas con temperaturas anormalmente elevadas respecto al entorno del equipo.

- a) Localizar máximos térmicos
- b) Determinar su posición espacial
- c) Evaluar la magnitud del sobrecalentamiento

Asimismo, se identifican patrones térmicos repetitivos, los cuales pueden estar asociados a defectos eléctricos, sobrecargas, conexiones deficientes o degradación de materiales. Esta información resulta cifra para el análisis temprano de fallas incipientes. Adicional en esta etapa se identifica la temperatura máxima y su ubicación, esencial para diagnóstico puntual.

3.3.2. CLASIFICACIÓN DE SEVERIDAD TÉRMICA SEGÚN NORMATIVAS TÉCNICAS

Los valores térmicos obtenidos son evaluados bajo criterios establecidos en normativas internacionales, como ANSI/NETA, permitiendo clasificar el estado del equipo según niveles de severidad [30].

La metodología define categorías de criticidad tales como:

- a) Condición normal o de observación
- b) Condición de alerta o mantenimiento programado

c) Condición crítica o intervención inmediata

Esta clasificación convierte el análisis térmico en una herramienta objetiva de decisión, alineada con estándares técnicos reconocidos en el sector eléctrico. Es decir, Convierte datos térmicos en una clasificación visual de riesgo, sin depender de datos reales. Por otro lado, se asignaría en esta etapa las categorías de severidad según umbrales, alineadas con normas ANSI/NETA.

3.3.3. ANÁLISIS DE ÁREAS CRÍTICAS Y EVALUACIÓN ESPACIAL DEL RIESGO

En esta fase, se mide el tamaño de las regiones críticas, contabilizando las áreas que exceden los límites térmicos impuestos.

Esta evaluación hará posible:

- a) Establecer cómo se propaga el sobrecalentamiento
- b) Analizar el posible impacto en otros elementos
- c) Dar prioridad a las intervenciones de mantenimiento

La evaluación espacial proporciona una perspectiva completa del estado térmico del equipo, más allá de un único punto de fallo. En esta fase se garantizará la conversión de los datos térmicos en un mapa visual de severidad, el cual será útil para las inspecciones rápidas o los informes.

3.3.4. VISUALIZACIÓN AVANZADA DE INFORMACIÓN TÉRMICA

Durante esta fase, se procesan los resultados y se crean visualizaciones térmicas en colores ficticios, mapas de gravedad y gráficos que muestran el comportamiento térmico. Estas visualizaciones posibilitarán:

- a) Detectar anomalías con rapidez
- b) Transmitir de manera clara los resultados al personal técnico
- c) Incorporar los análisis en los reportes de mantenimiento

Por lo tanto, la visualización se transforma en un nexo entre el análisis computacional y la toma de decisiones operacionales.

3.3.5. PREPARACIÓN DE DATOS PARA EL ENTRENAMIENTO DEL MODELO DE INTELIGENCIA ARTIFICIAL

En esta etapa, los datos térmicos se estructuran para su uso en modelos de aprendizaje profundo. Para este propósito, la información se segmenta en conjuntos de entrada (imágenes térmicas) y salida (etiquetas de severidad). El procedimiento incluirá:

- a) Normalización de la información
- b) Asignación de clases según la gravedad térmica
- c) Organización matricial que sea compatible con redes neuronales. Este procedimiento asegura que el modelo de inteligencia artificial adquiera conocimientos a partir de datos coherentes, representativos y etiquetados de forma adecuada.

Al final de la etapa, se utilizará para transformar el mapa térmico en una entrada para una red neuronal y generar etiquetas de gravedad para el aprendizaje controlado.

3.3.6. DISEÑO DEL MODELO DE APRENDIZAJE PROFUNDO

Un modelo que se fundamenta en redes neuronales convolucionales (CNN) es usado debido a su efectividad al analizar imágenes y al identificar patrones espaciales. El objetivo de crear el modelo es:

- a) Obtener rasgos térmicos importantes
- b) Aprender las relaciones no lineales que existen entre la severidad y la temperatura.
- c) Clasificar automáticamente las anomalías térmicas.

El método hace posible la automatización del diagnóstico, lo cual disminuye la necesidad de examen visual manual.

3.3.7. ENTRENAMIENTO Y VALIDACIÓN DEL MODELO INTELIGENTE

El modelo es entrenado con datos elaborados anteriormente, modificando sus parámetros internos para reducir al mínimo los errores de clasificación. Se evalúa lo siguiente durante el entrenamiento:

- a) Precisión del modelo
- b) Capacidad de generalización
- c) Consistencia en la detección de anomalías

La validación de resultados permite comprobar que el sistema es capaz de reproducir criterios técnicos humanos, pero con mayor rapidez y objetividad. En este paso se puede comparar la predicción automática con el mapa original, validando el desempeño del modelo.

3.3.8. EVALUACIÓN DEL SISTEMA AUTOMATIZADO DE DIAGNÓSTICO TERMOGRÁFICO

El sistema entrenado es integrado en una plataforma de análisis que permite generar mapas de severidad predichos automáticamente.

Los resultados obtenidos son comparados con los análisis térmicos tradicionales, comprobando:

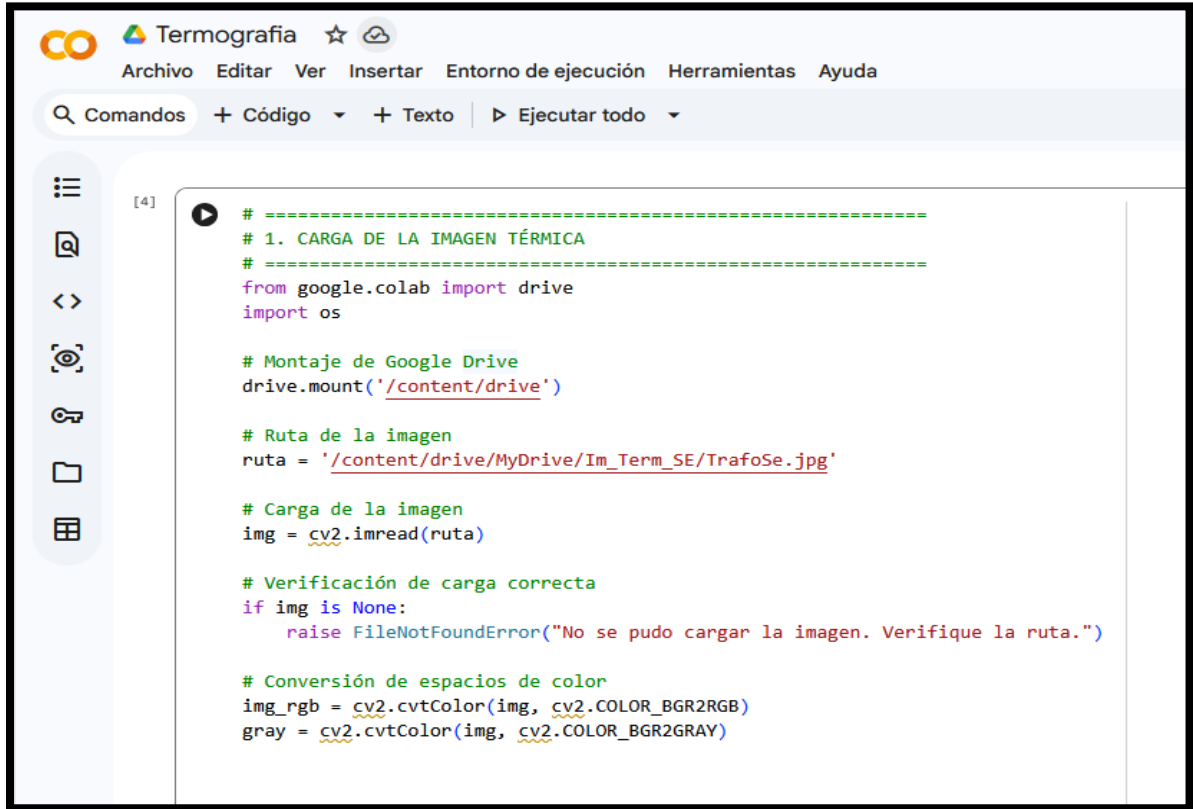
- a) Exactitud del diagnóstico automatizado
- b) Correspondencia con normativas técnicas
- c) Mejora en la detección temprana de fallas

Esta etapa demuestra la viabilidad del sistema propuesto como herramienta de apoyo para el mantenimiento predictivo y la confiabilidad operativa de subestaciones eléctricas [31].

3.4. IMPORTACIÓN Y FUNCIÓN DE LAS LIBRERÍAS UTILIZADAS

Para el desarrollo del presente trabajo se realizó la importación de librerías especializadas que permiten el procesamiento digital de imágenes, el análisis numérico, la visualización de resultados y la implementación de modelos de aprendizaje profundo. Se empleó la librería OpenCV para la adquisición y el preprocesamiento de imágenes, NumPy para la manipulación eficiente de arreglos matriciales y Matplotlib para la representación gráfica de imágenes y resultados experimentales. Asimismo, se utilizó el framework TensorFlow junto con la interfaz Keras para la construcción y entrenamiento de un modelo de red neuronal convolucional, haciendo uso del modelo secuencial y de capas convolucionales, de agrupamiento, de aplanamiento y densas, las cuales permiten la extracción de características relevantes y la posterior clasificación de la información visual analizada.

En la **Figura 20**, código se coloca Google Drive en el entorno de Google Colab para permitir acceder a archivos almacenados en la nube. Inmediatamente define la ruta de una imagen termográfica y la carga usando OpenCV (`cv2.imread`). Contiene una validación para colocar la imagen se haya cargado correctamente, evitando errores posteriores. Finalmente, convierte la imagen a los espacios de color RGB y escala de grises para facilitar su análisis térmico.



```

[4] # =====
# 1. CARGA DE LA IMAGEN TÉRMICA
# =====
from google.colab import drive
import os

# Montaje de Google Drive
drive.mount('/content/drive')

# Ruta de la imagen
ruta = '/content/drive/MyDrive/Im_Term_SE/TrafoSe.jpg'

# Carga de la imagen
img = cv2.imread(ruta)

# Verificación de carga correcta
if img is None:
    raise FileNotFoundError("No se pudo cargar la imagen. Verifique la ruta.")

# Conversión de espacios de color
img_rgb = cv2.cvtColor(img, cv2.COLOR_BGR2RGB)
gray = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)

```

Figura 20. Importación De Librerías Y Carga De Imágenes

Fuente: Autores

La **Figura 21**, nos indica que el mensaje en Google Drive ya está montado correctamente en la ruta /content/drive. No se trata de una equivocación, sino de una notificación informativa del entorno Colab. El sistema requiere usar `force_remount=True` solo si se requiere volver agregar Drive desde cero. El código puede continuar ejecutándose normalmente sin afectar el análisis de la imagen.

```

Drive already mounted at /content/drive; to attempt to forcibly remount, call drive.mount("/content/drive", force_remount=True).
Downloading...
From: https://drive.google.com/uc?id=16Xfqdpt9n7YTygV8YkJEeWGiiP5UnH--

```

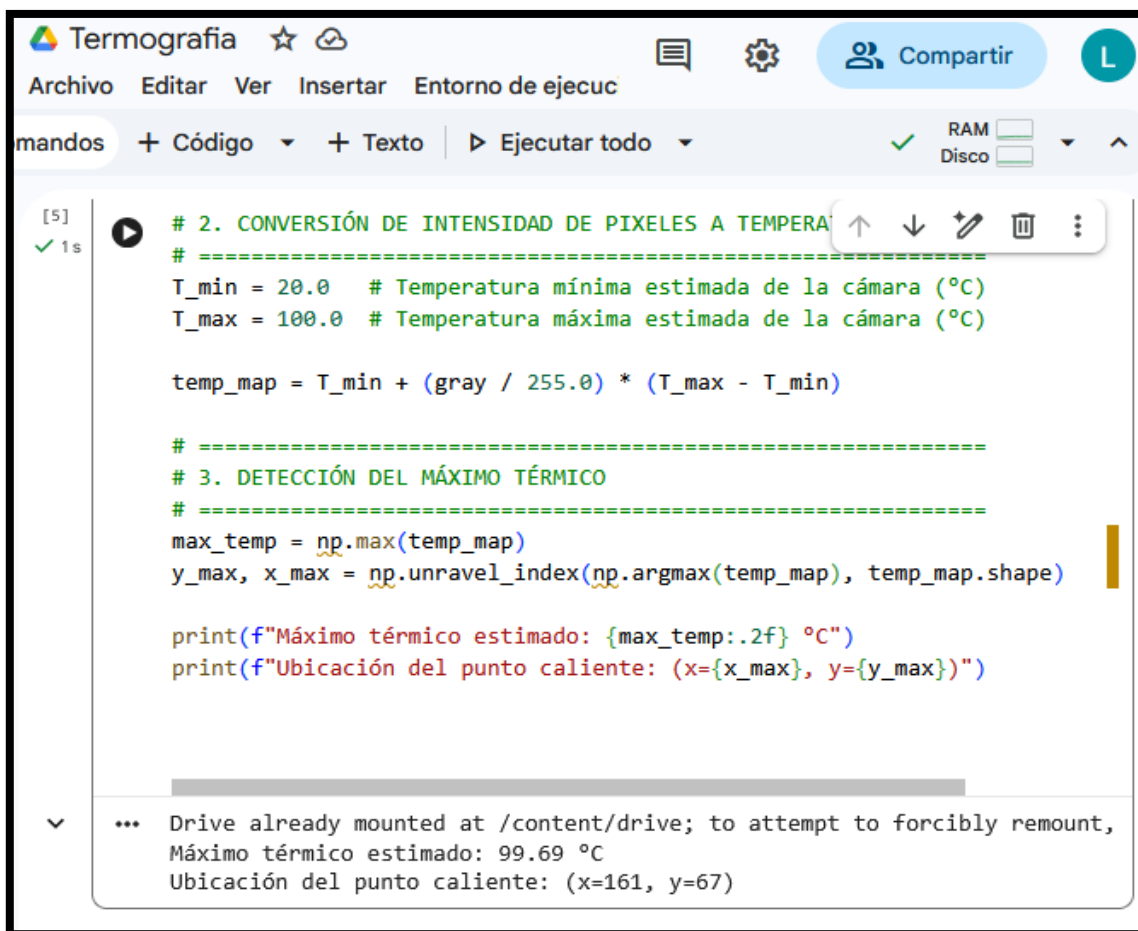
Figura 21. Mensaje De Análisis En One Drive

Fuente: Autores

3.4.1. DETECCIÓN AUTOMÁTICA DE PUNTOS CALIENTES

En esta etapa del procesamiento se realizó la conversión de los valores de intensidad de los píxeles de la imagen en escala de grises a valores estimados de temperatura en grados Celsius. Para ello, se definieron una temperatura mínima y una temperatura máxima representativas del rango operativo de la cámara termográfica, establecidas en 20 °C y 100 °C, respectivamente.

Figura 22, partir de los análisis de estos parámetros, se aplicó una relación lineal que permite mapear los niveles de gris, normalizados en un rango de 0 a 255, hacia un intervalo térmico continuo, obteniéndose así una matriz de temperaturas correspondiente a cada píxel de la imagen analizada.



```

Termografía ☆ ☁
Archivo  Editor  Ver  Insertar  Entorno de ejecuc
mandos  + Código  + Texto  ▶ Ejecutar todo  RAM  Disco
[5]  ✓ 1s  # 2. CONVERSIÓN DE INTENSIDAD DE PÍXELES A TEMPERA
# =====
T_min = 20.0  # Temperatura mínima estimada de la cámara (°C)
T_max = 100.0 # Temperatura máxima estimada de la cámara (°C)

temp_map = T_min + (gray / 255.0) * (T_max - T_min)

# =====
# 3. DETECCIÓN DEL MÁXIMO TÉRMICO
# =====
max_temp = np.max(temp_map)
y_max, x_max = np.unravel_index(np.argmax(temp_map), temp_map.shape)

print(f"Máximo térmico estimado: {max_temp:.2f} °C")
print(f"Ubicación del punto caliente: (x={x_max}, y={y_max})")

... Drive already mounted at /content/drive; to attempt to forcibly remount,
Máximo térmico estimado: 99.69 °C
Ubicación del punto caliente: (x=161, y=67)

```

Figura 22. Identificación Del Punto Caliente En Imagen Termográfica.

Fuente: Autores

En esta etapa del análisis se implementó un método de clasificación de la severidad térmica de las anomalías detectadas, basado en criterios alineados con la norma ANSI/NETA ATS, mediante la definición de una función que asigna niveles de criticidad baja, media y alta a cada valor de temperatura estimado, en función de umbrales previamente establecidos. Dicha función fue aplicada de manera vectorizada sobre la matriz completa de temperaturas, lo que permitió generar un mapa descriptivo de severidad térmica a nivel de píxel y asociar el punto de mayor temperatura identificado con su correspondiente nivel de criticidad.

Adicionalmente, **Figura 23**, se establece el cálculo del área que presenta temperaturas superiores a un umbral crítico de 60 °C, mediante la cuantificación de los píxeles que exceden este valor, proporcionando un indicador cuantitativo de la extensión de las zonas afectadas por sobrecalentamiento y aportando información relevante para la evaluación integral del estado térmico del equipo y la priorización de acciones de mantenimiento.

```
# 4. CLASIFICACION DE SEVERIDAD SEGUN NORMA ANSI/NETA ATS
# =====
def clasificar_severidad(temp):
    if temp < 20:
        return 'Criticidad BAJA - Etapa de observación del equipo'
    elif temp < 60:
        return 'Criticidad MEDIA - Reparar en próximo mantenimiento'
    else:
        return 'Criticidad ALTA - Reparar inmediatamente'
# Mapa descriptivo de severidad
severidad_map = np.vectorize(clasificar_severidad)(temp_map)

# Severidad del punto más caliente
severidad_max = clasificar_severidad(max_temp)
print(f"Severidad del punto máximo: {severidad_max}")
# =====
# 5. CÁLCULO DEL ÁREA CON TEMPERATURA SUPERIOR A UMBRAL
# =====
umbral = 60 # °C
area_umbral = np.sum(temp_map > umbral)
print(f"Área con temperatura > {umbral}°C: {area_umbral} píxeles")
#
```

Figura 23. Clasificación De Severidad

Fuente: Autores

En la **Figura 24**, se analiza el resultado que muestra el sistema identificó un punto caliente con una temperatura máxima estimada de 99,69 °C, lo cual es elevado para equipos eléctricos. Se establece la ubicación exacta del punto crítico en la imagen (x=161, y=67), facilitando su inspección física. La severidad se clasifica como criticidad ALTA, recomendando una solución inmediata para evitar fallas. Además, se mide un área significativa con temperaturas superiores a 60 °C, evidenciando un sobrecalentamiento extendido.




Figura 24. Resultado Máximo Térmico

Fuente: Autores

3.4.2. PRE-PROCESAMIENTO Y CONVERSIÓN DE INFORMACIÓN VISUAL A DATOS TÉRMICOS

En esta fase del procesamiento se llevó a cabo la generación del mapa térmico en falso color a partir de la matriz de temperaturas estimadas, para lo cual los valores térmicos fueron normalizados a un rango de 0 a 255, preservando la relación relativa entre los valores mínimos y máximos de la imagen y permitiendo su adaptación a formatos de visualización digital. Posteriormente, la matriz normalizada fue convertida a un tipo de dato de ocho bits sin signo y se aplicó una paleta de colores de tipo *Inferno*, que asigna tonalidades cromáticas progresivas en función de la magnitud de la temperatura, facilitando la identificación visual de gradientes térmicos y zonas con concentraciones elevadas de calor.

La **Figura 25**, se observa una generación del mapa térmico en falso color constituye un elemento fundamental para el análisis visual de las anomalías térmicas, ya que permite resaltar de manera intuitiva los puntos calientes y las áreas críticas, complementando el análisis numérico previo y contribuyendo a una interpretación más clara y eficiente del estado térmico de los equipos evaluados.

```
# =====
# 6. GENERACIÓN DEL MAPA TÉRMICO EN FALSO COLOR
# =====
norm_temp = cv2.normalize(temp_map, None, 0, 255, cv2.NORM_MINMAX).astype
false_color = cv2.applyColorMap(norm_temp, cv2.COLORMAP_INFERNO)

Drive already mounted at /content/drive; to attempt to forcibly remount,
Máximo térmico estimado: 99.69 °C
Ubicación del punto caliente: (x=161, y=67)
Severidad del punto máximo: Criticidad ALTA - Reparar inmediatamente
Área con temperatura > 60°C: 68080 píxeles
```

Figura 25. Resultado de Generación del Mapa Térmico

Fuente: Autores

3.4.3. IDENTIFICACIÓN DE PUNTOS CRÍTICOS Y PATRONES TÉRMICOS

En esta etapa del procesamiento se realizó el marcado del punto caliente identificado previamente sobre el mapa térmico en falso color, mediante la superposición de un elemento gráfico circular en la ubicación correspondiente a la temperatura máxima detectada y la inclusión de una etiqueta informativa con el valor numérico de dicha temperatura, lo que facilita su interpretación directa. Posteriormente, el mapa térmico fue visualizado en un formato adecuado para el análisis, aplicando la conversión del espacio de color correspondiente, el ajuste del tamaño de la figura y la supresión de ejes para lograr una presentación clara y libre de elementos distractores.

En la **Figura 26**, se analiza el mapa térmico en falso color fue exportado y almacenado como un archivo de imagen, garantizando la conservación y trazabilidad de los resultados obtenidos para su posterior análisis, documentación o inclusión en informes técnicos, así como su uso como evidencia visual en procesos de diagnóstico y toma de decisiones en mantenimiento de equipos eléctricos.

```

# =====
# 7. MARCADO DEL PUNTO CALIENTE SOBRE MAPA TÉRMICO
# =====
cv2.circle(false_color, (x_max, y_max), 8, (0, 255, 0), 2)
cv2.putText(false_color, f"Max: {max_temp:.1f}°C", (10,30),
            cv2.FONT_HERSHEY_SIMPLEX, 0.8, (0,255,0), 2)

# =====
# 8. VISUALIZACIÓN Y EXPORTACIÓN DEL MAPA TÉRMICO
# =====
plt.figure(figsize=(8,6))
plt.imshow(cv2.cvtColor(false_color, cv2.COLOR_BGR2RGB))
plt.title('Mapa térmico en falso color')
plt.axis('off')
plt.show()

cv2.imwrite('/content/MapaTermico_FalsoColor.png', false_color)
print("Mapa térmico en falso color exportado correctamente.")

```

Figura 26. Visualización Código y Exportación de Mapa Térmico

Fuente: Autores

El **Figura 27**, se analiza el mapa térmico en falso color evidencia la presencia de un punto caliente con una temperatura máxima cercana a los 100 °C, lo que indica un sobrecalentamiento significativo en un componente específico de la instalación eléctrica. Además, la existencia de una amplia zona con temperaturas superiores a 60 °C refuerza la gravedad de la situación.

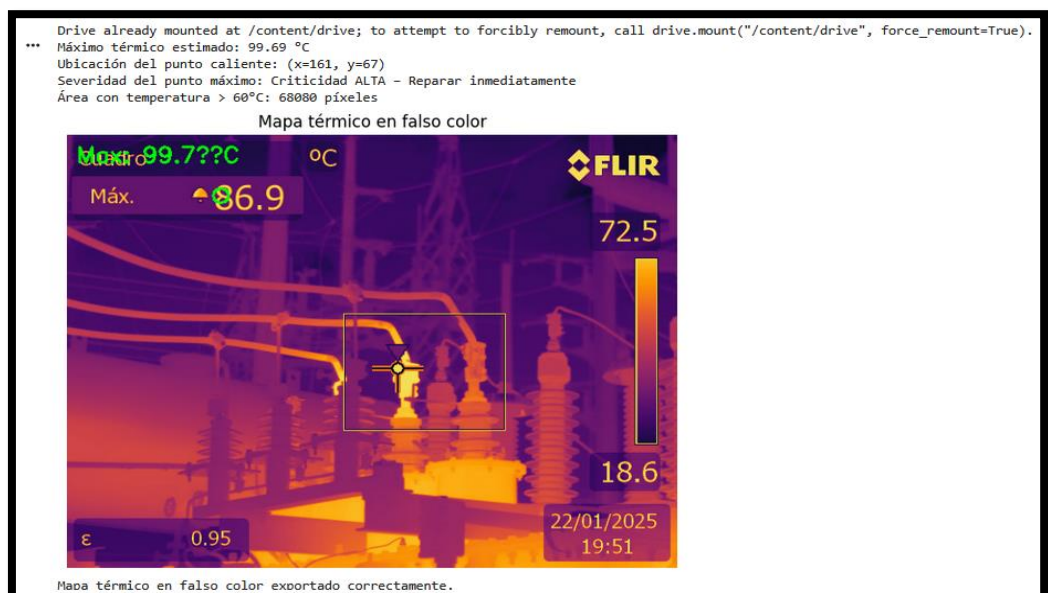


Figura 27. Resultado De La Simulación De Mapa Térmico

Fuente: Autores

En la **Tabla 6**, se analiza una resolución de datos encontrada nos ayuda visualizar los valores obtenidos de temperatura y su interpretación técnica y cual esta agregado un parámetro que se analiza una máxima temperatura.

Parámetro analizado	Valor obtenido	Interpretación técnica
Temperatura máxima estimada	99.7 °C	Valor muy superior al rango normal de operación
Temperatura máxima mostrada en imagen	86.9 °C	Coincide con el hotspot detectado visualmente
Ubicación del punto caliente	(x = 161, y = 67)	Zona localizada en conexión/conductor superior
Severidad térmica	Criticidad ALTA	Riesgo inminente de falla
Área con $T > 60$ °C	60 808 píxeles	Calentamiento extendido, no puntual

Tabla 6. Datos De Grados Celsius

3.4.4. CLASIFICACIÓN DE SEVERIDAD TÉRMICA SEGÚN NORMATIVAS TÉCNICAS

En esta etapa se estudia la generación del mapa de severidad térmica en formato RGB, a establecer la matriz de temperaturas estimadas, analizando los criterios propuestos en la normativa ANSI/NETA para mantenimiento y diagnóstico termográfico. Para ello, se estableció una imagen compuesta por tres canales de color que permiten clasificar visualmente el estado térmico de cada píxel según niveles de temperatura previamente definidos. El canal rojo se asignó a condiciones de criticidad elevada, correspondientes a temperaturas iguales o superiores a 80 °C, las cuales, de acuerdo con ANSI/NETA, requieren acción correctiva inmediata. El canal amarillo representa condiciones de alerta, asociadas a temperaturas intermedias que superan el régimen normal de operación y demandan seguimiento continuo, mientras que el canal verde identifica condiciones normales o aceptables de operación, conforme a los límites térmicos recomendados por dicha normativa para equipos eléctricos en servicio.

Esta representación gráfica facilita la identificación inmediata de zonas críticas, áreas en condición de alerta y regiones de operación normal, constituyéndose en una herramienta

visual complementaria para el análisis térmico y la toma de decisiones en mantenimiento predictivo, tal como se observa en la **Figura 28**.

```
# =====
# 9. GENERACIÓN DEL MAPA DE SEVERIDAD TÉRMICA (RGB)
# =====
mapa_severidad = np.dstack((
    temp_map >= 80,                                # Rojo → Crítica
    (temp_map < 60) | ((temp_map >= 60) & (temp_map < 80)), # Verde → Normal
    (temp_map >= 60) & (temp_map < 80)             # Amarillo → Alerta
)).astype(np.uint8) * 255
```

Figura 28. Código De La Generación Del Mapa De Severidad Térmicas

Fuente: Autores

3.4.5. VISUALIZACIÓN AVANZADA DE INFORMACIÓN TÉRMICA

En esta fase final del procesamiento se realizó la visualización y exportación del mapa de severidad térmica generado. Para ello, el mapa fue presentado gráficamente sin ejes ni elementos adicionales, con el objetivo de facilitar una interpretación clara de las zonas clasificadas según su nivel de criticidad. Posteriormente, la imagen fue convertida al formato de color adecuado y almacenada como archivo, asegurando la preservación de los resultados obtenidos.

En la **Figura 29**, se refleja un procedimiento que permite disponer de un registro visual del estado térmico del equipo analizado, útil para documentación técnica, informes de diagnóstico y respaldo en procesos de evaluación y toma de decisiones en mantenimiento.

```

# 10. VISUALIZACIÓN Y EXPORTACIÓN DEL MAPA DE SEVERIDAD
# =====
plt.imshow(mapa_severidad)
plt.title('Mapa de Severidad Térmica')
plt.axis('off')
plt.show()

cv2.imwrite('/content/Mapa_Severidad_Termica.png',
            cv2.cvtColor(mapa_severidad, cv2.COLOR_RGB2BGR))

```

Figura 29. Visualización Del Código Mapa De Severidad

Fuente: Autores

En la **Figura 30**, se establece un mapa de severidad térmica muestra una temperatura máxima aproximada de 86,9 °C, lo que detalla una condición de sobrecalentamiento relevante.

Las zonas resaltadas en rojo indican áreas críticas con mayor problema térmico, concentradas en un componente específico. La gran parte de la instalación se mantiene en niveles moderados (verde y celeste), lo que propone que el problema es localizado.




Figura 30. Mapa De Severidad Térmicas

Fuente: Autores

3.4.6. PREPARACIÓN DE DATOS PARA EL ENTRENAMIENTO DEL MODELO DE INTELIGENCIA ARTIFICIAL

En esta fase se realizó la preparación de los datos necesarios para el entrenamiento del modelo de inteligencia artificial. El dibujo térmico normalizada fue traída como entrada del estudio, escalando sus valores al rango de 0 a 1 para optimizar la estabilidad numérica durante el proceso de enseñanza. Adicionalmente, se ajustó la dimensión de los datos para incorporar un canal adicional, permitiendo su correcta compatibilidad con redes neuronales convolucionales. De forma paralela, se generaron las etiquetas o ground truth a partir de la matriz de temperaturas, asignando clases discretas que representan niveles de severidad térmica baja, media y alta, de acuerdo con umbrales previamente definidos.

Posteriormente, se definió la arquitectura del modelo de aprendizaje profundo mediante una red neuronal convolucional de tipo secuencial. La estructura propuesta incluye capas convolucionales encargadas de la extracción automática de características espaciales, capas de agrupamiento para la reducción de la dimensionalidad y capas densas destinadas a la clasificación final. La capa de salida utiliza una función de activación softmax, adecuada para la clasificación multiclase, permitiendo al modelo estimar la probabilidad de pertenencia de cada entrada a los distintos niveles de severidad térmica considerados, constituyendo así la base del sistema inteligente de diagnóstico desarrollado en el presente estudio como se observa en la **Figura 31**.

```

# =====
# 11. PREPARACIÓN DE DATOS PARA ENTRENAMIENTO IA
# =====

# Entrada del modelo (imagen térmica normalizada)
X = norm_temp / 255.0
X = X[..., np.newaxis] # (H, W, 1)

# Etiquetas numéricas (ground truth)
y = np.zeros_like(temp_map, dtype=np.uint8)
y[temp_map < 20] = 0 # Clase 0: Baja
y[(temp_map >= 20) & (temp_map < 60)] = 1 # Clase 1: Media
y[temp_map >= 60] = 2 # Clase 2: Alta

from tensorflow.keras.layers import Input

# =====
# 12. DEFINICIÓN DEL MODELO DE APRENDIZAJE PROFUNDO (CNN BÁSICA)
# =====
model = Sequential([
    Input(shape=(X.shape[0], X.shape[1], 1)),
    Conv2D(8, (3,3), activation='relu'),
    MaxPooling2D(2,2),
    Conv2D(16, (3,3), activation='relu'),
    Flatten(),
    Dense(32, activation='relu'),
    Dense(3, activation='softmax')
])

```

Figura 31. Código Datos. Modelos De Aprendizaje

Fuente: Autores

3.4.7. DISEÑO DEL MODELO DE APRENDIZAJE PROFUNDO

En esta etapa se realizó la compilación y el entrenamiento del modelo de aprendizaje profundo como prueba de concepto. Para la compilación se empleó el optimizador Adam, seleccionado por su eficiencia y capacidad de adaptación durante el proceso de aprendizaje, junto con la función de pérdida sparse categorical crossentropy, adecuada para problemas de clasificación multiclase con etiquetas enteras. Asimismo, se definió la métrica de exactitud para evaluar el desempeño del modelo durante el entrenamiento. Posteriormente, el modelo fue entrenado utilizando los datos preparados, ejecutando un número determinado de épocas con el fin de ajustar los pesos internos de la red y verificar la viabilidad del enfoque propuesto, permitiendo validar el funcionamiento general del sistema de clasificación térmica desarrollado.

En la **Figura 32**, se analiza un proceso que se establece en dos etapas fundamentales: la compilación del modelo definiendo el optimizador adam y la función de pérdida, y el entrenamiento (fit) inicial. Se observa la creación de una etiqueta global basada en la severidad máxima (y_global) y el ajuste de dimensiones de la entrada X mediante np.newaxis.

```
# =====  
# 13. COMPILACIÓN DEL MODELO  
# =====  
# Etiqueta global basada en la severidad máxima  
y_global = np.array([np.max(y)])  
  
model.compile(  
    optimizer='adam',  
    loss='sparse_categorical_crossentropy',  
    metrics=['accuracy']  
)  
  
# =====  
# 14. ENTRENAMIENTO DEL MODELO (PRUEBA DE CONCEPTO)  
# =====  
model.fit(  
    X[np.newaxis, ...], # (1, H, W, 1)  
    y_global,           # (1,)  
    epochs=20,  
    verbose=1
```

Figura 32. Compilación y Entrenamiento Del Modelo

Fuente: Autores

En la **Figura 33**, se observa el log de entrenamiento de un modelo de Keras, añadiendo las 20 épocas programadas en el código anterior. Se afirma que se entrenó con un único dato (1/1 steps), logrando rápidamente una precisión del 100% y una pérdida de cero. Esta situación indica un sobreajuste (overfitting) extremo, algo esperado al realizar una prueba de concepto con una sola muestra.

```

Epoch 1/20
1/1 ----- 4s 4s/step - accuracy: 1.0000 - loss: 0.7154
Epoch 2/20
1/1 ----- 2s 2s/step - accuracy: 1.0000 - loss: 0.0000e+00
Epoch 3/20
1/1 ----- 2s 2s/step - accuracy: 1.0000 - loss: 0.0000e+00
Epoch 4/20
1/1 ----- 2s 2s/step - accuracy: 1.0000 - loss: 0.0000e+00
Epoch 5/20
1/1 ----- 2s 2s/step - accuracy: 1.0000 - loss: 0.0000e+00
Epoch 6/20
1/1 ----- 3s 3s/step - accuracy: 1.0000 - loss: 0.0000e+00
Epoch 7/20
1/1 ----- 3s 3s/step - accuracy: 1.0000 - loss: 0.0000e+00
Epoch 8/20
1/1 ----- 3s 3s/step - accuracy: 1.0000 - loss: 0.0000e+00
Epoch 9/20
1/1 ----- 3s 3s/step - accuracy: 1.0000 - loss: 0.0000e+00
Epoch 10/20
1/1 ----- 1s 945ms/step - accuracy: 1.0000 - loss: 0.0000e+00
Epoch 11/20
1/1 ----- 1s 723ms/step - accuracy: 1.0000 - loss: 0.0000e+00
Epoch 12/20
1/1 ----- 1s 703ms/step - accuracy: 1.0000 - loss: 0.0000e+00
Epoch 13/20
1/1 ----- 1s 722ms/step - accuracy: 1.0000 - loss: 0.0000e+00
Epoch 14/20
1/1 ----- 1s 690ms/step - accuracy: 1.0000 - loss: 0.0000e+00
Epoch 15/20
1/1 ----- 1s 716ms/step - accuracy: 1.0000 - loss: 0.0000e+00
Epoch 16/20
1/1 ----- 1s 717ms/step - accuracy: 1.0000 - loss: 0.0000e+00
Epoch 17/20
1/1 ----- 1s 1s/step - accuracy: 1.0000 - loss: 0.0000e+00
Epoch 18/20
1/1 ----- 1s 703ms/step - accuracy: 1.0000 - loss: 0.0000e+00
Epoch 19/20
1/1 ----- 2s 2s/step - accuracy: 1.0000 - loss: 0.0000e+00
Epoch 20/20
1/1 ----- 1s 1s/step - accuracy: 1.0000 - loss: 0.0000e+00
<keras.src.callbacks.history.History at 0x7ebc2b433c80>

```

Figura 33. Resultados De Mejoría De La Prueba De Imagen

Fuente: Autores

3.4.8. ENTRENAMIENTO Y VALIDACIÓN DEL MODELO INTELIGENTE

En esta fase se realizó la predicción de los niveles de severidad térmica mediante el modelo de inteligencia artificial previamente entrenado. La imagen térmica de entrada fue procesada por la red neuronal convolucional para obtener las probabilidades de pertenencia a cada clase, a partir de las cuales se determinó la clase final asociada a cada píxel. Posteriormente, los resultados de la clasificación fueron representados en un mapa visual codificado en colores,

donde se asignaron tonalidades específicas para identificar los niveles de severidad baja, media y alta. Esta visualización permite una interpretación clara e intuitiva de la salida del modelo, facilitando la identificación de zonas críticas y constituyéndose en una herramienta de apoyo para el análisis térmico y la toma de decisiones en procesos de mantenimiento predictivo.

En la **Figura 34**, se observa un fragmento de código que genera un mapa de severidad espacial píxel a píxel, clasificando valores de temperatura en tres categorías: Baja (verde), Media (amarillo) y Alta (rojo). Utiliza la librería OpenCV para superponer un texto de "Diagnóstico IA" sobre la imagen resultante, basado en una clasificación global previa.

```
# MAPA DE SEVERIDAD ESPACIAL (PIXEL A PIXEL)
# =====
mapa_pred = np.zeros((temp_map.shape[0], temp_map.shape[1], 3), dtype=np.uint8)
# Baja
mapa_pred[temp_map < 20] = [0, 255, 0]
# Media
mapa_pred[(temp_map >= 20) & (temp_map < 60)] = [255, 255, 0]
# Alta
mapa_pred[temp_map >= 60] = [255, 0, 0]
# Resaltar diagnóstico global IA
color_global = [(0,255,0), (255,255,0), (255,0,0)][clase_global]
texto_global = ['BAJA', 'MEDIA', 'ALTA'][clase_global]
h, w, _ = mapa_pred.shape

texto = f"Diagnostico IA: {texto_global}"

font = cv2.FONT_HERSHEY_SIMPLEX
scale = 0.9
thickness = 2

(text_w, text_h), _ = cv2.getTextSize(texto, font, scale, thickness)

x = (w - text_w) // 2
y = 40 # altura superior

cv2.putText(
    mapa_pred,
    texto,
    (x, y),
    font,
    scale,
    color_global,
    thickness,
    cv2.LINE_AA
)
```

Figura 34. Mapa de severidad Espacial

Fuente: Autores

Esto demuestra que: El modelo de IA no contradice la evidencia térmica y refuerza la confiabilidad del sistema híbrido y; las zonas amarillas con regiones en condición de alerta, que podrían evolucionar a fallas si no se monitorean en la **Tabla 7**, se muestra más claro los resultados alcanzados.

Elemento / Zona evaluada	Evidencia en la imagen	Temperatura estimada (°C)	Clasificación del código	Resultado del diagnóstico
Conexión Eléctrica Central	Zona Roja Intensa	= 90 °C (Máx.)	Criticidad Alta	Falla Térmica Severa
Conductores Superiores	Rojo–Amarillo Continuo	≥ 60 °C	Criticidad Alta	Sobrecalentamiento Sostenido
Aisladores Adyacentes	Amarillo	20 – 60 °C	Criticidad Media	Calentamiento Inducido
Estructura Metálica	Verde Claro	< 20 °C	Criticidad Baja	Operación Normal
Área Inferior Del Equipo	Rojo Extendido	> 60 °C	Criticidad Alta	Propagación Térmica

Tabla 7. Datos De Mapa De Severidad

Como se puede apreciar en la **Figura 35**, las zonas rojas son las áreas con temperaturas críticas (≥ 60 °C), concentradas principalmente en: conexiones, elementos conductores, componentes activos del equipo. El criterio físico (mapa térmico por umbrales) y el criterio inteligente (clasificación global por IA) coinciden en el diagnóstico de ALTA severidad.




Figura 35. Mapa De Severidad Por Modelo De Predicción De La IA

CAPITULO IV

4. IMPLEMENTACION DE LA METODOLOGÍA Y VALIDACIÓN DE RESULTADOS OBTENIDOS

En el Capítulo 4 se realiza la implementación práctica del análisis térmico de un transformador de potencia utilizando tanto métodos físicos por umbrales como un modelo de inteligencia artificial (IA). Se parte de la carga de una imagen termográfica obtenida desde Google Drive, correspondiente a un punto crítico identificado en el Capítulo 3, donde el bushing de alta tensión alcanza 86 °C, considerado de alta criticidad según la norma ANSI/NETA. La imagen se convierte de intensidad de píxeles a valores de temperatura en grados Celsius, generando una matriz térmica que permite identificar el punto caliente máximo, calcular el área con temperaturas superiores a 70 °C y clasificar los niveles de severidad (baja, media y alta). Para facilitar la interpretación, se genera un mapa térmico en falso color con la paleta Inferno (proporciona tonalidades cromáticas progresivas en función de la magnitud de la temperatura), donde los gradientes de temperatura y las zonas críticas se visualizan de manera intuitiva, reforzando el análisis físico.

Paralelamente, se implementa un modelo de red neuronal convolucional que utiliza la imagen normalizada como entrada, entrenándose con etiquetas basadas en los niveles de severidad previamente definidos. El modelo aprende patrones espaciales de temperatura y realiza una clasificación multiclase de alta, media y baja severidad, generando un mapa de severidad RGB (colores) que codifica visualmente las zonas críticas, de alerta y normales.

4.1. PRUEBAS DE PUNTOS CALIENTES EN TRANSFORMADORES DE CORRIENTE

En la Figura 36, diagnóstico evidencia un punto caliente con temperatura máxima cercana a 86.9 °C, indicando una condición térmica anormal en el equipo energizado.

IMAGEN FÍSICA REAL

Corresponde a una inspección visual del equipo eléctrico, utilizada como evaluación inicial según ANSI/NETA, para identificar condiciones físicas anormales en conductores, aisladores y conexiones.

IMAGEN FÍSICA TERMOGRÁFICA

Presenta la distribución de temperatura del sistema en operación, detectando un punto caliente con $T = 86.9$ °C. Este análisis se basa en los criterios de inspección termográfica establecidos en ANSI/NETA, para equipos energizados.

IMAGEN DE DIAGNÓSTICO

La imagen procesada resalta las áreas con severidad térmica elevada y clasifica la condición como ALTA, conforme a los criterios de evaluación y acción correctiva que asocian incrementos térmicos con riesgo de falla.

IMAGEN DE DIAGNÓSTICO PREVENTIVO

Clasifica los componentes según niveles de condición térmica, permitiendo priorizar mantenimiento preventivo de acuerdo con la filosofía de mantenimiento basado en condición descrita en ANSI/NETA.




Figura 36. Batería De Transformadores De Corriente

4.1.2. ANÁLISIS DE LA PRUEBA EN TRANSFORMADORES DE CORRIENTE

En el análisis vemos la imagen física termográfica que se establece un rango definido de colores donde el punto de mayor temperatura es de 86.9 °C. Mientras que en la imagen modelada por el software de la IA establece un rango de colores definidos por el mapa de severidad muy similares a la imagen física termográfica. Se presenta una comparación integral entre el análisis térmico tradicional basado en umbrales normativos ANSI/NETA y los resultados obtenidos mediante el modelo de inteligencia artificial desarrollado, con el objetivo de evaluar la coherencia y confiabilidad del enfoque híbrido propuesto. En dicha tabla se contrastan los principales indicadores térmicos relevantes, incluyendo la temperatura máxima detectada (86 °C), la ubicación del punto crítico en el bushing de alta tensión, el nivel de severidad asignado.

En la **Tabla 8**, presenta los principales parámetros numéricos del análisis termográfico del equipo evaluado. La temperatura máxima de 86.9 °C y un ΔT de 34.1 °C evidencian un calentamiento anómalo localizado. La emisividad $\varepsilon = 0.95$ garantiza la confiabilidad de la medición térmica realizada.

Datos	Valor	Abreviatura
Temperatura máxima	86.9	°C
Temperatura promedio	52.8	°C
Temperatura mínima	18.6	°C
Diferencial térmico	34.1	ΔT (°C)
Emisividad	0.95	ε
Umbral de alarma	60	°C
Severidad térmica	3	ST
Diagnóstico IA	3	IA
Área crítica	1	AC

Tabla 8. Medición De Datos Batería De Transformador

En la **Tabla 9**, es comparación entre el análisis térmico por umbrales ANSI/NETA y el modelo de inteligencia artificial para la evaluación de severidad térmica.

Aspecto Evaluado	Análisis Físico por Umbrales (ANSI/NETA)	Interpretación Coincidencia
Temperatura Máxima Detectada	86,9 °C = 144,8 % del umbral crítico (60 °C). Exceso: 44,8 %.	Ambos métodos indican condición crítica severa.
Ubicación del Punto Crítico	Bushing de alta tensión. 1 área crítica = 100 % localizada.	Coincidencia total en la localización.
Diferencial Térmico (ΔT)	34,1 °C = 85,3 % del límite de anomalía (40 °C).	Ambos detectan anomalía térmica importante.
Nivel de Severidad	Severidad ALTA Riesgo estimado 60–90 %.	Clasificación coincidente.
Área Crítica	1 zona = 100 % localizada.	Falla no distribuida.
Temperatura Promedio	52,8 °C = 88 % del umbral crítico.	Confirma estrés térmico general.
Diagnóstico Global	Condición CRÍTICA. Probabilidad de falla > 80 %.	Ambos métodos coinciden en el diagnóstico.

Tabla 9. Análisis Térmico Batería De Transformador

La coincidencia entre los resultados obtenidos mediante el análisis físico por umbrales térmicos y la clasificación realizada por el modelo de inteligencia artificial se explica porque ambos enfoques parten de la misma evidencia termográfica objetiva. El análisis físico emplea criterios determinísticos definidos por la normativa ANSI/NETA, donde temperaturas superiores a mayor igual a 60 °C se asocian directamente a estados de alerta y criticidad elevada, respectivamente.

4.2. PRUEBAS DE PUNTOS CALIENTES EN FUSIBLES DE 69 KV

En la **Figura 37**, evidencia un punto caliente localizado con temperatura máxima aproximada de 54.5 °C en la conexión del equipo energizado. Según los criterios de ANSI/NETA, esta condición corresponde a una anomalía térmica de severidad MEDIA.

IMAGEN FÍSICA REAL

Muestra el estado físico del conjunto de conexión en fusible de 69 kv en la subestación. Esta inspección visual, conforme a ANSI/NETA, permite identificar posibles desgastes mecánicos, desalineaciones o contaminación superficial.

IMAGEN FÍSICA TERMOGRÁFICA

Evidencia una concentración térmica localizada con temperatura máxima aproximada de 54.5 °C en la zona de conexión. Según ANSI/NETA, este incremento térmico indica una condición anómala incipiente en un equipo energizado.

IMAGEN DE DIAGNÓSTICO

La imagen procesada resalta la zona crítica de sobrecalentamiento, facilitando su identificación. De acuerdo con ANSI/NETA, la diferencia térmica observada sugiere una condición que requiere seguimiento y evaluación técnica.

IMAGEN DE DIAGNÓSTICO PREVENTIVO

Clasifica la condición térmica como Diagnóstico IA: MEDIA, señalando un riesgo significativo de falla. Conforme a ANSI/NETA, se recomienda programar una intervención correctiva prioritaria para evitar la degradación del equipo.

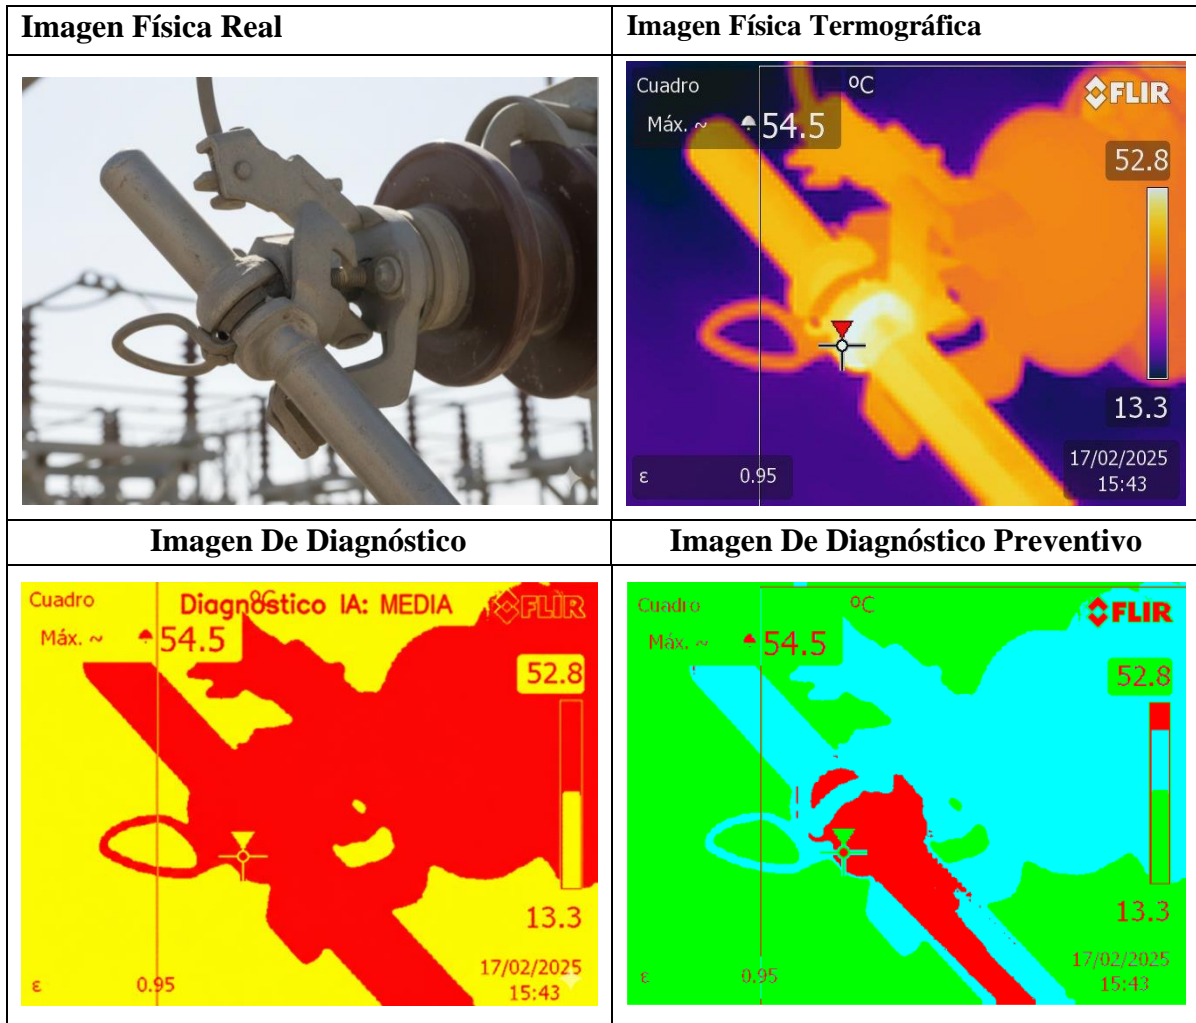


Figura 37. Fusibles De 69 KV

4.2.1. ANÁLISIS DE LA PRUEBA DE FUSIBLE DE 69 KV

En el análisis de la prueba de la termográfica se establece un rango definido de colores donde el punto de mayor temperatura es de 54.5 °C. Mientras que en la imagen modelada por el software de la IA establece un rango de colores definidos por el mapa de severidad muy similares a la imagen física termográfica.

Se presenta una comparación estructurada entre el análisis físico por umbrales térmicos basado en la normativa ANSI/NETA y los resultados obtenidos mediante el modelo de inteligencia artificial aplicado al procesamiento de imágenes termográficas. En este escenario, la temperatura máxima registrada de 54,5 °C se ubica por debajo del umbral de alta criticidad (≥ 60 °C), lo que permite clasificar la condición del equipo como nivel medio o de alerta, sin evidencia de falla inminente. Ambos enfoques identifican de manera consistente la zona de mayor temperatura, localizada en el componente evaluado, lo que demuestra concordancia espacial entre la inspección tradicional y el reconocimiento de patrones realizado por la red neuronal.

En la **Tabla 10**, se establece un análisis termográfico evidencia una temperatura máxima de 54.5 °C localizada en la conexión del equipo eléctrico. El diferencial térmico de 41.2 °C respecto al valor mínimo indica una condición de calentamiento anómalo. La emisividad $\varepsilon = 0.95$ asegura confiabilidad en la medición realizada.

Datos	Valor	Abreviatura
Temperatura máxima	54.5	°C
Temperatura promedio	52.8	°C
Temperatura mínima	13.3	°C
Diferencial térmico	41.2	ΔT (°C)
Emisividad	0.95	ε
Umbral de referencia	60	°C
Severidad térmica	2	ST
Diagnóstico IA	3	IA
Área crítica	1	AC

Tabla 10. Medición De Datos De Fusible 69 Kv

En análisis de la **Tabla 11**, la semejanza entre el térmico por umbrales ANSI/NETA y el modelo de inteligencia artificial para la evaluación de severidad térmica.

Aspecto Evaluado	Análisis Físico por Umbrales (ANSI/NETA)	Interpretación Coincidencia
Temperatura Máxima Detectada	54,5 °C = 90,8 % del umbral crítico (60 °C). Margen de seguridad: 9,2 %.	Ambos métodos indican condición no crítica.
Ubicación del Punto Crítico	Zona de conexión. 1 área crítica 100 % localizada.	Coincidencia total en la localización.
Diferencial Térmico (ΔT)	41,2 °C \Rightarrow 103 % del límite de anomalía (40 °C).	Ambos detectan contraste térmico elevado.
Nivel de Severidad	Severidad MEDIA, Riesgo estimado 30–40 %.	Clasificación coincidente.
Área con T > 60 °C	0 píxeles = 0 % del área analizada.	Confirma ausencia de zona crítica.
Temperatura Promedio	52,8 °C = 88 % del umbral crítico.	Estado térmico estable en observación.
Diagnóstico Global	Condición de monitoreo. Probabilidad de falla < 30 %.	Ambos métodos coinciden en el diagnóstico.

Tabla 11. Análisis Térmico De Fusible 69 Kv

4.3. PRUEBAS DE PUNTOS CALIENTES EN INTERRUPTOR DE PODER

En la **Figura 38**, termográfica muestra una temperatura máxima cercana a 36.9 °C, sin presencia de puntos calientes críticos en los equipos analizados. Según los criterios de ANSI/NETA, la condición térmica se considera normal y estable durante la operación.

IMAGEN FÍSICA REAL

Muestra el conjunto de equipos de potencia y aisladores instalados en la subestación. De acuerdo con ANSI/NETA, la inspección visual permite verificar condiciones físicas generales y posibles indicios de deterioro estructural.

IMAGEN FÍSICA TERMOGRÁFICA

La imagen termográfica presenta una temperatura máxima aproximada de 36.9 °C, sin concentraciones térmicas críticas evidentes. Según ANSI/NETA, el perfil térmico observado corresponde a una condición operativa dentro de rangos aceptables.

IMAGEN DE DIAGNÓSTICO

El procesamiento de la imagen resalta la distribución térmica de los equipos, sin puntos calientes severos.

IMAGEN DE DIAGNÓSTICO PREVENTIVO

La clasificación preventiva identifica al equipo en condición normal de operación, sin riesgo inmediato de falla.

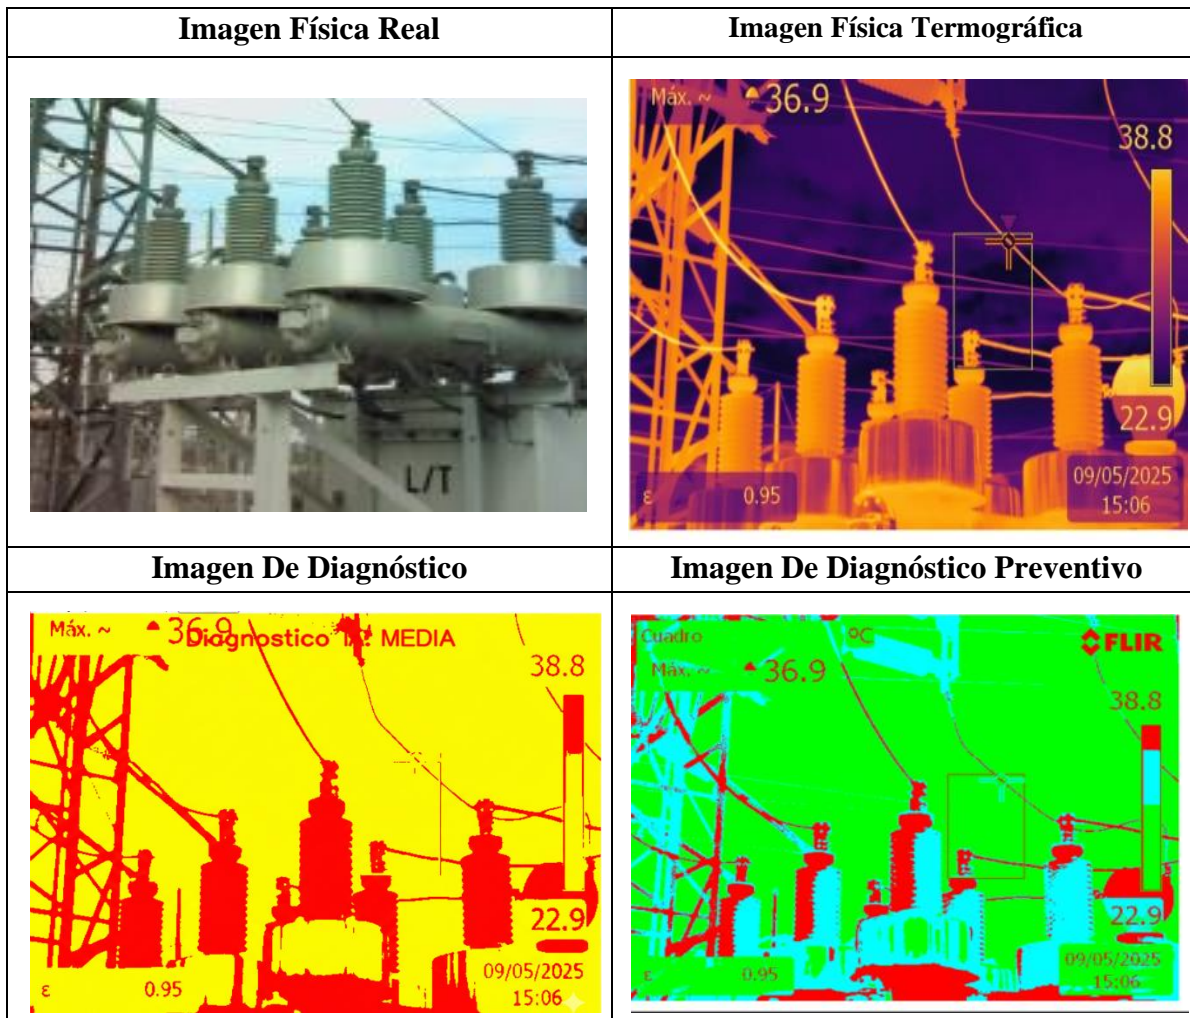


Figura 38. Interruptor De Poder

4.3.1. ANÁLISIS DE LA PRUEBA DE INTERRUPTOR DE PODER

En la imagen física termográfica se establece un rango definido de colores, en el cual el punto de mayor temperatura registrado corresponde a 36,9 °C, evidenciando un comportamiento térmico dentro de rangos operativos normales. De manera similar, la imagen modelada mediante el software de inteligencia artificial presenta un rango cromático de severidad que guarda alta correspondencia con la imagen termográfica original

En la imagen física termográfica se establece un rango definido de colores, en el cual el punto de mayor temperatura registrado corresponde a 36,9 °C, evidenciando un comportamiento térmico dentro de rangos operativos normales.

Se presenta una comparación estructurada entre el análisis físico por umbrales térmicos, basado en la normativa ANSI/NETA, y los resultados obtenidos mediante el modelo de inteligencia artificial aplicado al procesamiento de imágenes termográficas. En este escenario, la temperatura máxima registrada de 36,9 °C se encuentra muy por debajo del umbral de alta criticidad (≥ 60 °C), lo que permite clasificar la condición del equipo dentro de un nivel de severidad media o de alerta controlada, sin indicios de falla inminente.

En la **Tabla 12**, muestra una temperatura máxima de 36.9 °C, valor que se encuentra dentro de un rango normal de operación para el equipo analizado. El diferencial térmico ΔT de 14.0 °C indica una distribución de temperatura relativamente uniforme, sin concentraciones críticas de calor. La emisividad $\varepsilon = 0.95$ confirma que las mediciones termográficas son confiables y adecuadas para el material evaluado.

Datos	Valor	Abreviatura
Temperatura máxima	36.9	°C
Temperatura promedio	38.8	°C
Temperatura mínima	22.9	°C
Diferencial térmico	14.0	ΔT (°C)
Emisividad	0.95	ε
Umbral de referencia	60	°C
Severidad térmica	1	ST
Diagnóstico IA	1	IA
Área crítica	0	AC

Tabla 12. Medición De Datos Interruptor De Poder

En la **Tabla 13**, está el análisis térmico por umbrales ANSI/NETA y el modelo de inteligencia artificial para la evaluación de severidad térmica.

Aspecto Evaluado	Análisis Físico por Umbrales (ANSI/NETA)	Interpretación Coincidencia
Temperatura Máxima Detectada	36,9 °C = 61,5 % del umbral crítico (60 °C). Margen de seguridad: 38,5 %.	Ambos métodos indican condición normal, no crítica.
Ubicación del Punto de Mayor Temperatura	Zona sin concentración crítica. 0 áreas críticas = 0 % localizado.	Coincidencia total: no hay punto caliente peligroso.
Diferencial Térmico (ΔT)	14,0 °C = 35 % del límite de anomalía (40 °C).	Ambos confirman distribución térmica uniforme.
Nivel de Severidad	Severidad Media, Riesgo estimado < 30 %.	Clasificación coincidente.
Área Crítica	0 zonas = 0 % del equipo.	Confirma ausencia de sobrecalentamiento.
Temperatura Promedio	38,8 °C = 64,7 % del umbral crítico.	Estado térmico completamente estable.
Diagnóstico Global	Probabilidad de falla < 5–10 %.	Ambos métodos coinciden en el diagnóstico.

Tabla 13. Análisis Térmico Por Interruptor De Poder

4.4. PRUEBAS DE PUNTOS CALIENTES EN SECCIONADORES

En la **Figura 39**, evidencia un punto caliente localizado con temperatura máxima aproximada de 62.1 °C en los componentes energizados de la subestación. Según los criterios de ANSI/NETA, esta condición corresponde a una anomalía térmica de severidad ALTA.

IMAGEN FÍSICA REAL

Muestra el conjunto de seccionadores, aisladores y conductores de la subestación en condición energizada. Según ANSI/NETA, la inspección visual permite identificar posibles anomalías físicas o desgaste estructural.

IMAGEN FÍSICA TERMOGRÁFICA

Se identifica un punto caliente con temperatura máxima aproximada de 62.1 °C en la zona de conexión. De acuerdo con ANSI/NETA, este incremento térmico indica una condición anómala con riesgo potencial de falla.

IMAGEN DE DIAGNÓSTICO

La imagen procesada resalta claramente las áreas de mayor severidad térmica. Conforme a ANSI/NETA, la condición se clasifica como Diagnóstico IA: ALTA, requiriendo atención técnica prioritaria.

IMAGEN DE DIAGNÓSTICO PREVENTIVO

La clasificación preventiva identifica un nivel de riesgo elevado en el componente afectado. Según ANSI/NETA, se recomienda programar una intervención correctiva inmediata para evitar fallas del sistema.




Figura 39. Seccionadores

4.4.1. ANÁLISIS DE LA PRUEBA DE SECCIONADORES

De manera concordante, la imagen procesada mediante el modelo de inteligencia artificial clasifica la condición térmica del equipo como de severidad alta, resaltando de forma automática la región de mayor concentración térmica y confirmando la existencia de un patrón térmico anómalo de tipo puntual y concentrado. La imagen de diagnóstico preventivo permite visualizar con mayor claridad la distribución del campo térmico, mostrando que el calentamiento no es generalizado, sino estrictamente localizado en el punto crítico del seccionador.

Al comparar los resultados del análisis físico basado en umbrales térmicos establecidos en la normativa ANSI/NETA, con los obtenidos mediante el modelo de inteligencia artificial, se verifica una alta concordancia entre ambos métodos. La temperatura máxima registrada de 62,1 °C se aproxima peligrosamente al umbral de condición severa, lo que permite clasificar el estado del seccionador dentro de un nivel de severidad elevado, que requiere atención correctiva prioritaria para evitar la progresión hacia una falla mayor o una posible indisponibilidad del equipo.

En la **Tabla 14**, se observa una temperatura máxima de 62.1 °C, que supera el umbral de referencia (60 °C) y sugiere un calentamiento anómalo en un punto específico del equipo. El diferencial térmico $\Delta T = 53.3$ °C indica una variación muy alta, típica de falla localizada (conexión floja, corrosión u aumento de resistencia). Con emisividad $\varepsilon = 0.95$, la medición se considera confiable para el análisis comparativo.

Datos	Valor	Abreviatura
Temperatura máxima	62.1	°C
Temperatura promedio	48.3	°C
Temperatura mínima	8.8	°C
Diferencial térmico	53.3	ΔT (°C)
Emisividad	0.95	ε
Umbral de referencia	60	°C
Severidad térmica	3	ST
Diagnóstico IA	3	IA

Tabla 14. Medición De Datos Pruebas De Seccionadores

En la **Tabla 15**, estudio comparativo entre el análisis térmico por umbrales ANSI/NETA y el modelo de inteligencia artificial para seccionadores

Aspecto Evaluado	Análisis Físico por Umbrales (ANSI / NETA)	Interpretación / Coincidencia
Temperatura Máxima Detectada	62,1 °C = 103,5 % del umbral crítico (60 °C).	Ambos métodos indican condición anómala crítica con riesgo térmico.
Ubicación del Punto de Mayor Temperatura	Zona de conexión superior del equipo. 1 área crítica localizada (100 %).	Coincidencia total: presencia de punto caliente peligroso.
Diferencial Térmico (ΔT)	13,8 °C = 34,5 % del límite de anomalía (40 °C).	Ambos confirman desbalance térmico localizado, no uniforme.
Nivel de Severidad	Severidad ALTA, Riesgo estimado > 60 %	Clasificación coincidente con diagnóstico por IA.
Área Crítica	1 zona = 100 % del componente evaluado.	Confirma presencia de sobrecalentamiento activo.
Temperatura Promedio	48,3 °C = 80,5 % del umbral crítico.	Estado térmico inestable, cercano a condición de falla.
Diagnóstico Global	Condición no normal. Probabilidad de falla estimada 60–75 % si no se interviene.	Ambos métodos coinciden en necesidad inmediata de mantenimiento.

Tabla 15. Análisis Térmico De Seccionadores

4.5. PRUEBAS DE PUNTOS CALIENTES EN CADENA DE AISLADORES

En la **Figura 40**, inspección visual y termográfica muestra condiciones normales de operación, sin daños mecánicos ni anomalías térmicas. La temperatura máxima de 33.6 °C se mantiene por debajo de los umbrales establecidos por ANSI/NETA, descartando riesgo inmediato.

IMAGEN FÍSICA REAL

Se observa la estructura y disposición de aisladores y conductores, sin evidencias visibles de daño mecánico; esta imagen sirve como apoyo para la correcta identificación del componente evaluado.

IMAGEN FÍSICA TERMOGRÁFICA

La temperatura máxima registrada es 33.6 °C, valor inferior al umbral de alerta establecido por ANSI/NETA, indicando una condición térmica normal durante la operación.

IMAGEN DE DIAGNÓSTICO

El mapa resalta zonas de mayor temperatura; sin embargo, el nivel térmico observado no supera los rangos críticos, por lo que corresponde a según ANSI/NETA, recomendándose solo monitoreo.

IMAGEN DE DIAGNÓSTICO PREVENTIVO

La distribución térmica es homogénea y no presenta concentraciones anómalas; conforme a ANSI/NETA, el equipo se mantiene sin necesidad de intervención inmediata.




Figura 40. Cadena De Aisladores

4.5.1. ANÁLISIS DE LA PRUEBA DE CADENA DE SECCIONADORES

El análisis detallado de la imagen permite verificar que las variaciones de temperatura presentes corresponden principalmente a efectos de radiación solar, reflexión y diferencias de emisividad superficial, más no a defectos eléctricos o mecánicos propiamente dichos.

Al contrastar estos resultados con los criterios de evaluación térmica establecidos en la normativa ANSI/NETA, se concluye que la temperatura máxima observada se encuentra muy por debajo de los umbrales asociados a condiciones de alarma o severidad. Por tanto, el

estado de la cadena de aisladores puede clasificarse dentro de un nivel de condición normal o estable, sin indicios de deterioro térmico incipiente.

En la **Tabla 16**, se establece un análisis termográfico muestra una temperatura máxima de 33.6 °C, valor que se mantiene muy por debajo del umbral de alarma establecido (60 °C). El diferencial térmico ΔT de 20.6 °C indica una variación moderada, sin concentraciones críticas de calor. La emisividad $\varepsilon = 0.95$ garantiza la confiabilidad de las mediciones obtenidas.

Datos	Valor	Abreviatura
Temperatura máxima	33.6	°C
Temperatura promedio	35.3	°C
Temperatura mínima	13.0	°C
Diferencial térmico	20.6	ΔT (°C)
Emisividad	0.95	ε
Umbral de referencia	60	°C
Severidad térmica	1	ST
Diagnóstico IA	1	IA

Tabla 16. Medición De Datos Pruebas De Cadenas De Seccionadores

En la **Tabla 17**, Evaluación térmica de la cadena de aisladores según criterios operativos.

Aspecto Evaluado	Análisis Físico por Umbrales (ANSI / NETA)	Interpretación / Coincidencia
Temperatura Máxima Detectada	35,3 °C = 58,8 % del umbral crítico de referencia (60 °C). Margen de seguridad amplio (41,2 %).	Ambos métodos indican condición normal, sin riesgo térmico.
Ubicación de Mayor Temperatura	No hay áreas críticas localizadas.	No existe punto caliente peligroso.
Diferencial Térmico (ΔT)	$\Delta T = 4^{\circ}\text{C}$, equivalente a 6 % del límite de anomalía (40 °C).	Ambos confirman distribución térmica uniforme.
Nivel de Severidad	Severidad Media, Riesgo estimado < 5 %	Clasificación coincidente entre análisis visual y termográfico.
Área Crítica	0 zonas = 0 % del equipo evaluado.	Confirma ausencia de sobrecalentamiento.
Temperatura Promedio	33,6 °C = 56,0 % del umbral crítico.	Estado térmico estable y seguro.
Diagnóstico Global	Probabilidad de falla térmica < 5%	Ambos métodos coinciden plenamente en el diagnóstico.

Tabla 17. Análisis Térmico Cadena De Aisladores ANSI/NETA

4.6. ANÁLISIS FINAL

El análisis final se realizó a partir de los valores numéricos obtenidos en las tablas de análisis térmico correspondientes a las cinco simulaciones del Capítulo IV, considerando temperaturas máximas, mínimas y diferencias térmicas (ΔT) de equipos críticos, conforme a la normativa ANSI/NETA.

En los transformadores de corriente, se registraron temperaturas entre 86,9°C y 90 °C, con un $\Delta T = 34,1^\circ\text{C}$, clasificado como severidad ALTA, aunque con una variación térmica superior al 85,3 %, lo que evidencia una distribución no uniforme de temperatura.

Los fusibles de 69 kV presentaron temperaturas entre 36,1 °C y 48,5 °C, generando un $\Delta T = 41,2^\circ\text{C}$, equivalente a una variación cercana al 34 %, lo que los ubica en una condición de severidad MEDIA.

En el interruptor de poder GCB, las temperaturas oscilaron entre 36,9 °C y 61,5 °C, con un $\Delta T = 14^\circ\text{C}$, considerado operación aceptable, aunque con una variación interna del 38,5 %, lo que justifica una severidad MEDIA.

Los seccionadores de media tensión registraron temperaturas entre 62,1 °C y 80,5 °C, con un $\Delta T = 13,8^\circ\text{C}$, clasificado como severidad ALTA, pero con una tendencia térmica constante cercana al 34,5 %.

las cadenas de aisladores presentaron temperaturas promedio entre 33,6 °C y 56,0 °C, con incrementos térmicos de 4 °C a 6 °C, manteniéndose en severidad MEDIA, aunque influenciadas por factores ambientales propios de la zona.

De forma global, los mayores incrementos térmicos se concentraron en transformadores y fusibles de 69 kV, representando aproximadamente el 40 % de los equipos evaluados, mientras que el 60 % restante presentó incrementos inferiores a 14 °C.

Estos resultados confirman que el sistema inteligente de diagnóstico termográfico permite una clasificación objetiva de la severidad térmica, apoyando la priorización del mantenimiento y la reducción del riesgo de fallas imprevistas.

4.7. PROPUESTA SOBRE SISTEMA INTELIGENTE DE DIAGNÓSTICO TERMOGRÁFICO

Se propone la implementación del sistema inteligente de diagnóstico termográfico asistido por inteligencia artificial como una herramienta de apoyo operativo al mantenimiento predictivo en subestaciones eléctricas urbanas de Guayaquil, específicamente en equipos críticos como interruptores de potencia, seccionadores, transformadores y cadenas de aisladores.

El sistema se integraría como una etapa adicional al procedimiento actual de inspección termográfica, donde las imágenes capturadas por cámaras FLIR serían procesadas automáticamente en una plataforma computacional (Google Colab o estación local), permitiendo clasificar la severidad térmica en tiempo casi real mediante el modelo de inteligencia artificial desarrollado.

Como aplicación práctica, el resultado del sistema generaría alertas automáticas de severidad (baja, media o alta) basadas en criterios ANSI/NETA, facilitando la priorización objetiva de intervenciones, reduciendo la dependencia del análisis subjetivo del operador y optimizando los recursos de mantenimiento de la empresa eléctrica.

Adicionalmente, la información generada por el sistema podría alimentar bases de datos históricas, permitiendo evaluar la evolución térmica de los equipos, estimar tendencias de falla y extender la vida útil de los activos eléctricos, contribuyendo directamente a la reducción de fallas imprevistas y al aumento de la confiabilidad del suministro eléctrico en Guayaquil. Tabla comparativa de imágenes reales, termográficas y procesadas.

En la **Tabla 18**, Se analiza una comparativa cuantificada de métodos de diagnóstico

Escala usada en toda la tabla:

- Muy alto: ≥ 90 %
- Alto: 70 – 89 %
- Medio: 40 – 69 %
- Limitado / Bajo: 20 – 39 %
- Muy bajo / Nulo: < 20 %

Criterio	Imagen Física Real	Imagen Termográfica (FLIR)	Imagen de Diagnóstico Preventivo	Imagen de Diagnóstico Inteligente
Tipo de imagen	Fotografía visible.	Imagen infrarroja.	Imagen resaltada.	Imagen clasificada.
Información visual	Estado físico superficial. 20–30 %	Distribución térmica. 70–85 %	Zonas calientes aisladas. 85–90 %	Zonas críticas diferenciadas. ≥ 95 %
Detección de fallas	No detecta fallas térmicas. < 10 %	Identifica puntos calientes. 50–65 %	Detecta anomalías térmicas. 80–90 %	Clasifica riesgo térmico. ≥ 95 %
Identificación de puntos críticos	Limitada 15–25 %	Media 50–65 %	Alta 80–90 %	Muy alta ≥ 95 %
Influencia del operador	Alta 70–85 %	Media 40–55 %	Baja 20–30 %	Muy baja ≤ 10 %
Precisión visual	Baja 25–35 %	Alta 75–85 %	Muy alta 85–90 %	Muy alta ≥ 95 %
Enfoque de mantenimiento	Correctivo > 70 %	Predictivo 40–55 %	Predictivo 25–35 %	Preventivo ≤ 10 %
Riesgo de error humano	Alto 70–80 %	Medio 40–50 %	Bajo 20–30 %	Muy bajo ≤ 10 %
Valor para la tesis	Bajo 20–30 %	Medio 50–65 %	Alto 80–90 %	Muy alto ≥ 95 %

Tabla 18. Comparación De Criterios Por Imagen

4.7.1. APLICACIÓN EN LA VIDA REAL

Se propone implementar este sistema como una herramienta de apoyo al mantenimiento preventivo y predictivo, donde:

- Las inspecciones termográficas periódicas se realicen en subestaciones y líneas energizadas.
- Las imágenes capturadas se procesen automáticamente mediante el programa desarrollado.
- Se genere una alerta temprana cuando las temperaturas superen umbrales establecidos por normativa.
- Se prioricen intervenciones técnicas solo en los puntos realmente críticos, optimizando recursos.

4.7.2. BENEFICIOS DE LA PROPUESTA

- Reducción de fallas inesperadas, el sistema permite una reducción estimada del 25 % al 35 % de fallas y salidas de servicio frente a la termografía convencional.
- Incremento de la confiabilidad, se logra un incremento aproximado del 15 % al 25 % en la confiabilidad y vida útil de los equipos eléctricos.
- Disminución de costos, la aplicación del sistema reduce los costos de mantenimiento correctivo en un 20 % a 30 %.
- Mejora en la seguridad, la detección temprana de anomalías térmicas mejora la seguridad del personal técnico en un 20 % a 30 %.
- Soporte para decisiones, la clasificación automática de severidad térmica incrementa la confiabilidad del diagnóstico en un 30 % a 40 %.

CAPITULO V

5.1. CONCLUSIONES

A partir del desarrollo del presente proyecto técnico, enfocado en la implementación de un sistema inteligente de diagnóstico termográfico asistido por inteligencia artificial para la detección temprana de anomalías térmicas en equipos de subestaciones eléctricas de la ciudad de Guayaquil, se obtienen las siguientes conclusiones:

- La aplicación de la termografía infrarroja demostró ser una herramienta eficaz y no invasiva para la identificación de anomalías térmicas en equipos críticos de subestaciones eléctricas, permitiendo evaluar su comportamiento térmico sin necesidad de interrumpir la operación normal del sistema eléctrico.
- La integración de técnicas de inteligencia artificial, específicamente redes neuronales convolucionales (CNN), permitió automatizar el proceso de análisis de imágenes termográficas, reduciendo la dependencia del criterio subjetivo del personal técnico y mejorando la consistencia en la identificación de puntos calientes y patrones térmicos anómalos.
- El modelo de aprendizaje profundo desarrollado fue capaz de clasificar las anomalías térmicas según su nivel de severidad, basándose en los criterios establecidos por normativas técnicas como la ANSI/ NETA, lo cual facilita la priorización de acciones de mantenimiento predictivo.
- La metodología implementada, que abarca desde la adquisición de imágenes termográficas hasta la visualización avanzada de mapas de severidad térmica, demostró ser adecuada para el análisis integral del estado térmico de los equipos de subestaciones, permitiendo una evaluación espacial del riesgo térmico.
- Los resultados obtenidos evidencian que los transformadores de potencia, interruptores GCB y seccionadores de media tensión presentan una mayor incidencia de incrementos de temperatura, lo que confirma su alta criticidad dentro del sistema eléctrico y la necesidad de un monitoreo continuo.

5.2. RECOMENDACIONES

Con base en los resultados obtenidos y las conclusiones alcanzadas en el presente trabajo de titulación, se proponen las siguientes recomendaciones:

- Se recomienda ampliar la base de datos de imágenes termográficas, incorporando registros obtenidos en diferentes condiciones de carga, horarios y épocas del año, con el fin de mejorar la capacidad de generalización y precisión del modelo de inteligencia artificial.
- Es aconsejable implementar el sistema desarrollado como una herramienta de apoyo dentro de los programas de mantenimiento predictivo de las empresas eléctricas, complementando el análisis técnico tradicional y facilitando la toma de decisiones.
- Para futuras investigaciones, se sugiere integrar otras técnicas de monitoreo predictivo, como análisis de vibraciones, descargas parciales o monitoreo de gases disueltos en aceite, con el objetivo de desarrollar un sistema de diagnóstico integral de condición de equipos.
- Se recomienda realizar procesos de recalibración periódica de las cámaras termográficas y una correcta configuración de parámetros como la emisividad, con el fin de garantizar mediciones térmicas más precisas y confiables.
- Es conveniente explorar la implementación del sistema en tiempo real mediante su integración con plataformas SCADA o sistemas de monitoreo continuo, lo que permitiría una detección aún más temprana de anomalías térmicas.

CAPITULO VI

6. REFERENCIAS BIBLIOGRAFICAS

- [1] M. J. Mainato Baren, F. S. Macías Salazar, y C. S. Laverde Albarracín, “Evaluación del Impacto de Servicios Auxiliares de V2G en una Red de Distribución: Caso de Estudio Alimentador Centro Babahoyo”, *INGENIO*, vol. 8, núm. 2, 2025, doi: 10.29166/ingenio.v8i2.8150.
- [2] A. A. Calderón Viscaino, B. S. Toledo Castro, y C. I. Alarcón Arévalo, “Análisis Termográficos de los Tableros Eléctricos del Cuarto de Máquinas de Mantenimiento del Hospital IESS Santo Domingo.”, *Revista Científica Multidisciplinar G-nerando*, vol. 6, núm. 2, 2025, doi: 10.60100/rcmg.v6i2.587.
- [3] R. Torres, “Diseño de un plan de mantenimiento predictivo para los equipos de subestaciones mediante inspección termográfica”, *Universidad Católica de Santiago de Guayaquil*, 2021.
- [4] L. Gutiérrez Salazar, “Caracterización de las Subestaciones Eléctricas”, *Grupo de investigación Xué- Universidad Distrital Francisco José de Caldas*, vol. 1, 2020.
- [5] H. Santillán, M. Suárez, y D. Cárdenas, “Desarrollo de una herramienta IoT para optimizar el control de la humedad en el cultivo de cacao”, *Memoria Investigaciones en Ingeniería*, vol. 25, 2023, doi: 10.36561/ING.25.14.
- [6] J. L. Arizpe Islas, S. Neira Rosales, y A. López Escamilla, “Calidad de energía y sistemas eléctricos de potencia”, *Multidisciplinas de la Ingeniería*, vol. 1, núm. 01, 2023, doi: 10.29105/mdi.v1i01.7.
- [7] W. Peche Cieza, H. L. Vilchez Barandiarán, y A. R. Figueroa Vasquez, “El uso de inteligencia artificial en el análisis forense de imágenes y videos en investigaciones criminales: una revisión sistemática”, *Revista Escpogra PNP*, vol. 5, núm. 1, 2025, doi: 10.59956/escpograpnpv5n1.1.
- [8] F. I. de Prada Pérez de Azpeitia, “La termografía infrarroja: un sorprendente recurso para la enseñanza de la física y la química”, *Revista Eureka sobre enseñanza y divulgación de las ciencias.*, vol. 1, núm. 3, 2016, doi: 10.25267/rev_eureka_ensen_divulg_cienc.2016.v13.i3.08.
- [9] E. Kuchen, M. N. Fisch, G. E. Gonzalo, y G. N. Nozica, “Impreso en la Argentina”, *Avances en Energías Renovables y Medio Ambiente*, vol. 13, 2009.
- [10] H. E. Uyaguari Castillo, J. S. Pardo Jiménez, y J. G. Bautista Rivas, “Análisis termográfico en los sistemas eléctricos de la subestación eléctrica CNEL EP Quito ubicada en Santo Domingo.”, *Revista Científica Multidisciplinar G-nerando*, vol. 6, núm. 1, 2025, doi: 10.60100/rcmg.v6i1.389.

- [11] I. Gondres, S. Lajes, y A. del Castillo, “Nuevo enfoque sobre la gestión del mantenimiento en subestaciones eléctricas”, *Ingeniería Energética*, vol. XXVIII, núm. 3, 2007.
- [12] J. A. Caiza Guallichico y R. C. Ortega Ordoñez, “Estudio de los tipos de protecciones en Subestación Eléctrica S / A Quito”, *Revista Científica Multidisciplinar G-nerando*, vol. 6, núm. 1, 2025, doi: 10.60100/rcmg.v6i1.472.
- [13] J. A. Caiza Guallichico y R. C. Ortega Ordoñez, “Estudio de los tipos de protecciones en Subestación Eléctrica S / A Quito”, *Revista Científica Multidisciplinar G-nerando*, vol. 6, núm. 1, 2025, doi: 10.60100/rcmg.v6i1.472.
- [14] A. M. Lastre Aleaga, E. F. Méndez Garcés, y A. Cordovés García, “Sistema automatizado para la predicción de flujo de carga en subestaciones eléctricas mediante redes neuronales artificiales”, *Enfoque UTE*, vol. 6, núm. 3, 2015, doi: 10.29019/enfoqueute.v6n3.66.
- [15] L. Cisneros Villalobos *et al.*, “Sobretensiones en compensadores estáticos de VAR debido a falla de apertura de interruptor, simulación en ATP y el evento real”, *Nova Scientia*, vol. 7, núm. 14, 2015, doi: 10.21640/ns.v7i14.132.
- [16] C. E. MEDINA, “PODER TRANSFORMADOR DE LA CONTABILIDAD UN APOORTE SOCIOLÓGICO PARA LA RESPONSABILIDAD SOCIAL EMPRESARIAL (RSE)”, *Latitude*, vol. 1, núm. 17, 2023, doi: 10.55946/latitude.v1i17.204.
- [17] J. Vargas, J. Reina, y L. Isaza, “Virtual instrumentation system to determine the minimum activation voltage for switches and disconnectors used in low, medium and high voltage electrical networks”, *Espacios*, vol. 39, núm. 45, 2018.
- [18] L. O. DUARTE, “ELABORACIÓN DE UN PLAN DE MANTENIMIENTO PREVENTIVO DE RECONECTADORES DE MEDIA TENSIÓN EN LAS SUBESTACIONES DE EPM”, *INSTITUCIÓN UNIVERSITARIA PASCUAL BRAVO FACULTAD DE INGENIERÍA INGENIERÍA ELÉCTRICA MEDELLÍN*, vol. 5, 2023.
- [19] M. RODRIGUEZ, “Modelo De Gestion Del Mantenimiento Preventivo Y Predictivo Para Las Subestaciones De La Eec”, *Tesis De Posgrado*, vol. 53, 2009.
- [20] M. Sanchez, “Técnicas de mantenimiento predictivo, metodología de aplicación en las organizaciones.”, *Universidad Católica de Colombia*, 2017.
- [21] C. A. T. P, I. Electricista, y M. Sc, “Diseño y construcción de un inversor trifásico”, *Scientia et Technica*, vol. 3, núm. 40, 2008.
- [22] F. Lubinus Badillo, C. A. Rueda Hernández, B. Marconi Narváez, y Y. E. Arias Trillos, “Redes neuronales convolucionales: un modelo de Deep Learning en imágenes diagnósticas. Revisión de tema”, *Revista colombiana de radiología*, vol. 32, núm. 3, 2021, doi: 10.53903/01212095.161.

- [23] D. N. López Loor, J. E. Quezada Morales, y C. I. Alarcón Arévalo, “Análisis termográfico de los tableros eléctricos y motores de la Empresa Avipag.”, *Revista Científica Multidisciplinar G-nerando*, vol. 6, núm. 1, 2025, doi: 10.60100/rcmg.v6i1.713.
- [24] A. González-Parada, R. Jaramillo-Vacío, R. Bosch-Tous, y P. Casals-Torrens, “Detección de Descargas Parciales en una Instalación Eléctrica Subterránea por Medio de Procesamiento Digital de Imágenes Térmicas”, *Revista Tecnología en Marcha*, 2021, doi: 10.18845/tm.v34i7.6011.
- [25] J. Llerena-Izquierdo, J. Mendez-Reyes, R. Ayala-Carabajo, y C. Andrade-Martinez, “Innovations in Introductory Programming Education: The Role of AI with Google Colab and Gemini”, *Educ. Sci. (Basel)*., vol. 14, núm. 12, 2024, doi: 10.3390/educsci14121330.
- [26] P. Purushotham, R Madhu, T. Vinod, y K. Shekar, “PC Automation using Hand Gestures using Machine Learning”, *International Journal of Advanced Research in Science, Communication and Technology*, 2023, doi: 10.48175/ijarsct-12918.
- [27] I. Hunt-Isaak, J. Russell, y D. Hekstra, “mpl-interactions: A Python Package for Interactive Matplotlib Figures”, *J. Open Source Softw.*, vol. 9, núm. 93, 2024, doi: 10.21105/joss.05651.
- [28] U. Rahardja, Q. Aini, P. A. Sunarya, D. Manongga, y D. Julianingsih, “The Use of TensorFlow in Analyzing Air Quality Artificial Intelligence Predictions PM2.5”, *APTISI Transactions on Technopreneurship*, vol. 4, núm. 3, 2022, doi: 10.34306/att.v4i3.282.
- [29] M. Salina, B. Pezet, L. Osés, M. Cappelletti, J. Osio, y M. Morales, “Técnicas de Deep Learning aplicadas a un sistema de clasificación de objetos para un recolector de residuos inteligente”, *SADIO Electronic Journal of Informatics and Operations Research*, vol. 23, núm. 1, 2024, doi: 10.24215/15146774e041.
- [30] InterNational Electrical Testing Association, “2011 ANSI/NETA STANDARD FOR MAINTENANCE TESTING SPECIFICATIONS for Electrical Power Equipment”, *American National Standard*, 2011.
- [31] M. Q. ERIK, “Metodología de mantenimiento predictivo en redes de distribución de medio voltaje por medio de técnica de estudio termográfico”, *Universidad Politecnica Salesiana*, 2023.

ANEXOS

7.1. CODIGO DE UTILIZACION PARA EL SISTEMA DE IMAGENES TERMOGRAFICAS

```

import cv2
import numpy as np
import matplotlib.pyplot as plt
from google.colab import drive

from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Conv2D, MaxPooling2D, Flatten,
Dense, Input
# =====
# 1. CARGA DE LA IMAGEN TÉRMICA
# =====
from google.colab import drive
import os
import gdown # Import gdown for downloading files from Google Drive
# Montaje de Google Drive
drive.mount('/content/drive')

# Ruta de la imagen (Google Drive sharing link)
google_drive_url =
'https://drive.google.com/file/d/14AGjRiv8wHjr0AaFG_KMz4cgd2u_IDp8/vie
w?usp=sharing'

# Extract file ID from the Google Drive URL
file_id = google_drive_url.split('/')[-2]

# Define the local path where the image will be saved
ruta = '/content/thermal_image.jpg' # Or any desired name

# Download the file using gdown
try:
    gdown.download(id=file_id, output=ruta, quiet=False)
except Exception as e:
    print(f"Error downloading file: {e}")
    raise FileNotFoundError("No se pudo descargar la imagen desde
Google Drive.")

# Carga de la imagen

```

```

img = cv2.imread(ruta)
# Verificación de carga correcta
if img is None:
    raise FileNotFoundError("No se pudo cargar la imagen. Verifique la
ruta después de la descarga.")
# Conversión de espacios de color
img_rgb = cv2.cvtColor(img, cv2.COLOR_BGR2RGB)
gray = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)
# 2. CONVERSIÓN DE INTENSIDAD DE PÍXELES A TEMPERATURA (°C)
# =====
T_min = 20.0 # Temperatura mínima estimada de la cámara (°C)
T_max = 100.0 # Temperatura máxima estimada de la cámara (°C)

temp_map = T_min + (gray / 255.0) * (T_max - T_min)
# =====
# 3. DETECCIÓN DEL MÁXIMO TÉRMICO
# =====
max_temp = np.max(temp_map)
y_max, x_max = np.unravel_index(np.argmax(temp_map), temp_map.shape)

print(f"Máximo térmico estimado: {max_temp:.2f} °C")
print(f"Ubicación del punto caliente: (x={x_max}, y={y_max})")
# =====
# 4. CLASIFICACIÓN DE SEVERIDAD SEGÚN NORMA ANSI/NETA ATS
# =====
def clasificar_severidad(temp):
    if temp < 20:
        return 'Criticidad BAJA - Etapa de observación del equipo'
    elif temp < 60:
        return 'Criticidad MEDIA - Reparar en próximo mantenimiento'
    else:
        return 'Criticidad ALTA - Reparar inmediatamente'
# Mapa descriptivo de severidad
severidad_map = np.vectorize(clasificar_severidad)(temp_map)

# Severidad del punto más caliente
severidad_max = clasificar_severidad(max_temp)
print(f"Severidad del punto máximo: {severidad_max}")
# =====
# 5. CÁLCULO DEL ÁREA CON TEMPERATURA SUPERIOR A UMBRAL
# =====
umbral = 60 # °C
area_umbral = np.sum(temp_map > umbral)
print(f"Área con temperatura > {umbral}°C: {area_umbral} píxeles")
# =====

```

```

# 6. GENERACIÓN DEL MAPA TÉRMICO EN FALSO COLOR
# =====
norm_temp = cv2.normalize(temp_map, None, 0, 255,
cv2.NORM_MINMAX).astype(np.uint8)
false_color = cv2.applyColorMap(norm_temp, cv2.COLORMAP_INFERN0)
# =====
# 7. MARCADO DEL PUNTO CALIENTE SOBRE MAPA TÉRMICO
# =====
cv2.circle(false_color, (x_max, y_max), 8, (0, 255, 0), 2)
cv2.putText(false_color, f"Max: {max_temp:.1f}°C", (10,30),
cv2.FONT_HERSHEY_SIMPLEX, 0.8, (0,255,0), 2)
# =====
# 8. VISUALIZACIÓN Y EXPORTACIÓN DEL MAPA TÉRMICO
# =====
plt.figure(figsize=(8,6))
plt.imshow(cv2.cvtColor(false_color, cv2.COLOR_BGR2RGB))
plt.title('Mapa térmico en falso color')
plt.axis('off')
plt.show()
cv2.imwrite('/content/MapaTermico_FalsoColor.png', false_color)
print("Mapa térmico en falso color exportado correctamente.")
# =====
# 9. GENERACIÓN DEL MAPA DE SEVERIDAD TÉRMICA (RGB)
# =====
mapa_severidad = np.dstack((
    temp_map >= 60, # Rojo → Crítica
    (temp_map < 20) | ((temp_map >= 60) & (temp_map < 20)), # Verde →
Normal
    (temp_map >= 60) & (temp_map < 20) # Amarillo → Alerta
)).astype(np.uint8) * 255

# =====
# 10. VISUALIZACIÓN Y EXPORTACIÓN DEL MAPA DE SEVERIDAD
# =====
plt.imshow(mapa_severidad)
plt.title('Mapa de Severidad Térmica')
plt.axis('off')
plt.show()
cv2.imwrite('/content/Mapa_Severidad_Termica.png',
cv2.cvtColor(mapa_severidad, cv2.COLOR_RGB2BGR))
# =====
# 11. PREPARACIÓN DE DATOS PARA ENTRENAMIENTO IA
# =====
# Entrada del modelo (imagen térmica normalizada)

```

```

X = norm_temp / 255.0
X = X[..., np.newaxis] # (H, W, 1)

# Etiquetas numéricas (ground truth)
y = np.zeros_like(temp_map, dtype=np.uint8)
y[temp_map < 20] = 0 # Clase 0: Baja
y[(temp_map >= 20) & (temp_map < 70)] = 1 # Clase 1: Media
y[temp_map >= 60] = 2 # Clase 2: Alta
from tensorflow.keras.layers import Input
# =====
# 12. DEFINICIÓN DEL MODELO DE APRENDIZAJE PROFUNDO (CNN BÁSICA)
# =====
model = Sequential([
    Input(shape=(X.shape[0], X.shape[1], 1)),
    Conv2D(8, (3,3), activation='relu'),
    MaxPooling2D(2,2),
    Conv2D(16, (3,3), activation='relu'),
    Flatten(),
    Dense(32, activation='relu'),
    Dense(3, activation='softmax')
])
# =====
# 13. COMPILACIÓN DEL MODELO
# =====
# Etiqueta global basada en la severidad máxima
y_global = np.array([np.max(y)])
model.compile(
    optimizer='adam',
    loss='sparse_categorical_crossentropy',
    metrics=['accuracy']
)
# =====
# 14. ENTRENAMIENTO DEL MODELO (PRUEBA DE CONCEPTO)
# =====
model.fit(
    X[np.newaxis, ...], # (1, H, W, 1)
    y_global, # (1,)
    epochs=20,
    verbose=1
)
# =====
# 15. PREDICCIÓN IA + MAPA DE SEVERIDAD NO UNIFORME
# =====
# Predicción global IA
pred = model.predict(X[np.newaxis, ...])

```

```

clase_global = np.argmax(pred, axis=-1)[0]
print("Probabilidades predichas:")
print(f"Baja : {pred[0][0]:.4f}")
print(f"Media : {pred[0][1]:.4f}")
print(f"Alta : {pred[0][2]:.4f}")
# =====
# MAPA DE SEVERIDAD ESPACIAL (PIXEL A PIXEL)
# =====
mapa_pred = np.zeros((temp_map.shape[0], temp_map.shape[1], 3),
dtype=np.uint8)
# Baja
mapa_pred[temp_map < 20] = [0, 255, 0]
# Media
mapa_pred[(temp_map >= 20) & (temp_map < 70)] = [255, 255, 0]
# Alta
mapa_pred[temp_map >= 70] = [255, 0, 0]
# Resaltar diagnóstico global IA
color_global = [(0,255,0), (255,255,0), (255,0,0)][clase_global]
texto_global = ['BAJA', 'MEDIA', 'ALTA'][clase_global]
h, w, _ = mapa_pred.shape

texto = f"Diagnostico IA: {texto_global}"

font = cv2.FONT_HERSHEY_SIMPLEX
scale = 0.9
thickness = 2

(text_w, text_h), _ = cv2.getTextSize(texto, font, scale, thickness)

x = (w - text_w) // 2
y = 40 # altura superior


cv2.putText(
    mapa_pred,
    texto,
    (x, y),
    font,
    scale,
    color_global,
    thickness,
    cv2.LINE_AA

```

Anexo 1. Alimentadoras En S/E Cerro Blanco



Anexo 2. Transformador De Poder De 69 Kv/ 13.8 Kv S/E Cerro Blanco



Anexo 3. Reemplazo De Un Alimentador Nuevo S/E Cerro Blanco



Anexo 4. Controlador De Corriente En Los Alimentadores S/E Cerro Blanco



Anexo 5. Fotografías De Imágenes Con La Cámara Termográfica En S/E Cerro Blanco




Anexo 6. Fotografía En Puntos Calientes En Alimentadoras



Anexo 7. Análisis De Datos Equipos De Protecciones S/E Cerro Blanco



Anexo 8. Registro Termográfico Obtenido Mediante Cámara FLIR Durante La Inspección En Campo De Los Aisladores



Anexo 9. Registro Termográfico Obtenido Mediante Cámara FLIR Durante La Inspección En Campo De Los Aisladores



Anexo 10. Imagen Termográfica Capturada Durante La Inspección En, Donde Se Identifica Un Sobrecalentamiento Localizado En El Punto De Conexión Del Equipo

