



POSGRADOS |

MAESTRÍA EN ELECTRICIDAD

RPC-SO-30-No.508-2019

OPCIÓN DE
TITULACIÓN:

ARTÍCULO PROFESIONAL DE ALTO NIVEL

TEMA:

DETECCIÓN DE FALLAS EN MOTORES ELÉCTRICOS UTILIZANDO
TERMOGRAFÍAS Y REDES NEURONALES

AUTOR:

ABRAHAN ELIAS ESPINOZA AGUILAR
RICARDO ANDRES PARRALES TOLEDO

DIRECTOR:

ING. XAVIER SERRANO GUERRERO Ph.D.

GUAYAQUIL-ECUADOR
2024

Autores:



Ricardo Andrés Parrales Toledo

Ingeniero Eléctrico

Candidato a Magíster en Electricidad, Mención Sistemas Eléctricos de Potencia por la Universidad Politécnica Salesiana, Sede Guayaquil

rparralest@est.ups.edu.ec

ricardoparrales34@gmail.com



Abraham Elias Espinoza Aguilar

Ingeniero Eléctrico

Candidato a Magíster en Electricidad, Mención Sistemas Eléctricos de Potencia por la Universidad Politécnica Salesiana, Sede Guayaquil

aespinozaa1@est.ups.edu.ec

abrahanelias@outlook.com

Dirigido por:



JOHNNY XAVIER SERRANO GUERRERO

Ingeniero Electrónico

Master Universitario en Tecnología Energética para el Desarrollo Sostenible en la Especialidad Eficiencia Energética.

Doctorado en Ingeniería y Producción Industrial

jserranog@ups.edu.ec

Todos los derechos reservados.

Queda prohibida, salvo excepción prevista en la Ley, cualquier forma de reproducción, distribución, comunicación pública y transformación de esta obra para fines comerciales, sin contar con autorización de los titulares de propiedad intelectual. La infracción de los derechos mencionados puede ser constitutiva de delito contra la propiedad intelectual. Se permite la libre difusión de este texto con fines académicos investigativos por cualquier medio, con la debida notificación a los autores.

DERECHOS RESERVADOS

©2024 Universidad Politécnica Salesiana.

GUAYAQUIL – ECUADOR – SUDAMÉRICA

RICARDO ANDRES PARRALES TOLEDO

ABRAHAN ELIAS ESPINOZA AGUILAR

**DETECCIÓN DE FALLAS EN MOTORES ELÉCTRICOS UTILIZANDO
TERMOGRAFÍAS Y REDES NEURONALES**

Detección de fallas en motores eléctricos utilizando termografías y redes neuronales

Fault detection in electric motors using thermography and neural networks.

Ricardo Andrés PARRALES TOLEDO

Universidad Politécnica Salesiana, Guayaquil, Ecuador, rparralest@est.ups.edu.ec

Abrahan Elías ESPINOZA AGUILAR

Universidad Politécnica Salesiana, Guayaquil, Ecuador, aespinozaa1@est.ups.edu.ec

Cite this paper as:

Parrales, R.A., Espinoza, A.E., Fault detection in electric motors using thermography and neural networks.

Abstract: The project addresses the detection of faults in electric motors through thermography and neural networks. It involves the study of concepts about alternating and direct current motors, their possible electrical and mechanical failures, the use of infrared thermography, the design and application of artificial and convolutional neural networks. The Cat S61 smartphone is used to generate thermographic reports classifying failures into severity levels. The neural network designed in Python, which includes 83 thermographic images, 3 convolutional layers, kernel filters, activations, and Softmax classifier, achieves a training accuracy of 59% and a validation accuracy of 71%. It uses TensorFlow's Keras interface and a Tkinter graphical interface to facilitate the use of the application. Tests show that the network is especially effective at detecting faults of mild and critical severity. This approach integrates advanced technologies to improve the diagnosis and maintenance of electric motors.

Keywords: *database, electric motors, neural networks, thermography infrared*

© 2023 Published by ICMECE

Nomenclatura	
AC	Corriente alterna
ANSI	Instituto Nacional de Normas Estadounidenses
API	Interfaz de programa de aplicación.
DC	Corriente continua
Dropout	Tasa de abandono
DL	Deep Learning (aprendizaje profundo)
ML	Machine Learning (aprendizaje automático)
Máx-pooling	Agrupamiento máximo
NETA	Asociación Internacional de Pruebas Eléctricas
Padding	Relleno
Pooling	Agrupación
ReLU	Unidad lineal rectificadora
RGB	Rojo, verde y azul.
RNA	Redes neuronales artificiales
RNC	Redes neuronales convolucionales
Stride	Pasos
T _{máx}	Temperatura máxima en °C
1,2,3D	1,2,3 dimensiones

1. INTRODUCCIÓN

En todo tipo de industrias se encuentra presente el motor eléctrico ya sea de corriente alterna AC o continua DC, por lo que se necesita tenerlos al máximo rendimiento posible. Los motores AC, son capaces de convertir la energía eléctrica en mecánica y se clasifican en síncronos y asíncronos. Además, operan en sistemas monofásicos y trifásicos, siendo estos últimos preferidos en la industria por su eficiencia. Los motores síncronos mantienen una velocidad constante y los asíncronos varían con la carga, destacando por su simplicidad y durabilidad en la industria [1]. Los motores DC generan movimiento mecánico induciendo un campo magnético polarizado al hacer circular corriente por sus bobinas. Además, ofrecen alto torque inicial y control preciso de velocidad ajustando la tensión. Estos motores se emplean ampliamente en aplicaciones que requieren control preciso de velocidad y torque, como en vehículos eléctricos, robótica, cintas transportadoras y herramientas eléctricas [2].

Los motores eléctricos son componentes esenciales en distintas industrias, fundamentales para asegurar operaciones eficientes y productivas [3]. Su mantenimiento en condiciones óptimas supone un desafío importante, dado el amplio espectro de posibles fallos mecánicos y eléctricos. La detección y corrección temprana de estos problemas son cruciales para prevenir fallos prematuros, evitar interrupciones productivas y minimizar la necesidad de reparaciones costosas o sustituciones [4].

En una máquina operando continuamente se puede originar algún problema provocando un aumento de temperatura y deterioro o ruptura del aislamiento de los devanados, carcasa, desgaste de los rodamientos u otros componentes mecánicos [5]. Las averías más comunes en los motores incluyen el desgaste de rodamientos y la degradación del aislamiento del bobinado. Los rodamientos, vitales para un funcionamiento fluido, pueden desgastarse por fricción, sobrecarga o insuficiente lubricación, impactando negativamente en la eficiencia y durabilidad del motor [6]. Paralelamente, el aislamiento del bobinado, clave para la seguridad y eficacia del motor, puede verse comprometido por exceso de calor, humedad o sobretensiones, lo que podría resultar en cortocircuitos o fallos eléctricos [4]. El sobrecalentamiento figura entre las causas principales de fallas en el aislamiento y los rodamientos. Estos factores suelen ser condiciones de la línea eléctrica, acciones del operador, sistemas de control, defectos intrínsecos del motor, localización del equipo y prácticas de mantenimiento, detallados en la Tabla I [7].

Tabla I. Fallas en el aislamiento y rodamientos del motor eléctrico por sobrecalentamiento

#	Causas	Origen	Procedencia	Averías
1	Condiciones de la línea eléctrica	Eléctrico	Sobrevoltaje, bajo voltaje, voltaje desbalanceado y conexión de alta resistencia	Bobinados del motor (causando calor excesivo por corrientes anormales)
2	Acciones del operador	Físico	Operación inadecuada o la sobrecarga del motor por parte de los operadores	Aumento de temperatura en todo el motor, especialmente en el rotor y los bobinados
3	Sistema de control	Electrónico	Sistemas de control mal configurados o inadecuados	Calentamiento excesivo en los circuitos de control y en los bobinados del motor
4	Defectos intrínsecos del motor	Mecánico y eléctrico	Vueltas cortocircuitadas, tierra en el bobinado y rodamientos desgastados	Puntos calientes que pueden dañar el aislamiento y otros componentes
5	Localización del equipo	Físico	Ambientes con alta temperatura ambiental o con flujo de aire restringido	Incremento de la temperatura de operación del motor, lo que afecta su eficiencia y durabilidad
6	Prácticas de mantenimiento	Mecánico, eléctrico y electrónico	Mantenimiento inadecuado, por ejemplo: correas demasiado ajustadas y problemas con las poleas	Aumento de fricción y calor en el eje y los rodamientos, así como en otros componentes del motor

Para abordar estos problemas, se aplica la técnica de termografía infrarroja, que emplea la radiación térmica para obtener imágenes en tiempo real de la temperatura de un objeto, permitiendo la detección de fallos

en equipos y estructuras [8]. Además, utiliza cámaras especializadas, las cuales acelera el diagnóstico y minimiza daños, ofreciendo ventajas como la capacidad de recopilar datos a distancia sin interrumpir el proceso operativo y la habilidad para escanear amplias áreas e identificar irregularidades [9]. En este caso se utiliza un smartphone serie S61 que posee un alcance de hasta 30 metros, el cual puede realizar mediciones incluso en la oscuridad. Cuenta con una batería de 4500 mAh y protección IP 68/69. La captura y análisis de imágenes termográficas se realiza a través de la aplicación MyFlir, la cual permite visualizar y medir temperaturas de forma no invasiva e identificar puntos de calor, fugas y deficiencias en aislamientos [10].

La detección térmica en la carcasa del motor es crucial, sobre todo si se registra una elevada temperatura (ver Figura 1), lo que amerita una inspección detallada. También es recomendable la revisión de los devanados, ya que el calentamiento por armónicos o transitorios de línea disminuye a la mitad su vida útil [11]. Estos bobinados poseen un aislamiento cuya temperatura máxima varía según la clase A, E, B, F y H, con límites de 105, 120, 130, 150 y 180°C; respectivamente [7].

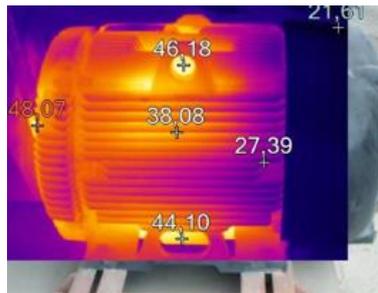


Figura 1. Termografía en la carcasa del motor.

Otro caso se presenta cuando la temperatura del rodamiento supera de 5 a 10°C a la de la carcasa del motor, podría indicar problemas como mala alineación del eje, lubricación inadecuada o rodamientos desgastados. Por último, se realiza una inspección en los bornes del motor, ya que cables rotos o excesivamente apretados pueden causar calentamiento [11].

Generalmente, se aplican criterios de severidad según las normativas ANSI (Instituto Nacional de Normas Estadounidense) y NETA (Asociación Internacional de Pruebas Eléctricas). Estas normativas implican realizar inspecciones y disponer de equipos de protección/medida. El propósito es identificar el objeto y equipo, describir las discrepancias y causas probables. Además, se debe definir cómo se evaluará la diferencia de temperatura (ver Tabla II), mostrar las condiciones de carga en tiempo real, generar imágenes termográficas del área afectada y sugerir acciones correctivas [12].

Tabla II. Niveles de severidad

Severidad	$\Delta T1$ [°C]		$\Delta T2$ [°C]		Deficiencia	Reparación
Leve	1	3	1	10	Posible	No requiere, pero si necesita una investigación previa
Moderada	4	15	11	20	Probable	En la siguiente parada del proceso
Grave	> 16		21	40	Está presente	Lo más pronto posible
Crítica	> 35		> 40		Mayor	Inmediata

Nota: $\Delta T1$ y $\Delta T2$ representan las diferencias de temperatura entre un valor máximo a uno de características similares y el ambiente; respectivamente.

La termografía juega un papel importante en los mantenimientos, ofreciendo un método no invasivo para la detección de fallas de la máquina [13]. Sin embargo, si el personal no interpreta correctamente los datos, puede tener errores en asignar los niveles de severidad sobre el motor y eso provocaría una gestión ineficaz del mantenimiento [14]. Para mitigar estos problemas, es crucial implementar un sistema de datos eficientes con herramientas de análisis automatizadas y priorizar las inspecciones basados en la criticidad de los problemas detectados. Estas medidas ayudan a optimizar el proceso de diagnóstico, mejorar la eficiencia operativa y asegurar un mantenimiento más efectivo y oportuno.

Una de las propuestas desarrolladas por Khanjani y Ezoji [14] se basa en un método automático que utiliza dos conjuntos, uno con el motor en vacío y otro con carga de 394 y 322 imágenes, respectivamente. Además, emplea técnicas de aprendizaje automático para la detección de fallos en máquinas de inducción trifásicas, donde se escoge el 70% para el entrenamiento y 30% en la validación de la red, cuyo desarrollo es en Matlab. Primero, se detecta la región de interés en las termogramas usando el método de transformación de

características invariantes de escala (SIFT). Luego, estas imágenes se convierten en vectores de características mediante la red neuronal convolucional (RNC) de tipo AlexNet. Los vectores se agrupan en clústeres¹ de frío y calor con el algoritmo K-means. Finalmente, se entrena un clasificador basado en máquinas de soporte vectorial (SVM) para cada clúster, que agrupa las muestras de prueba. Este método muestra una precisión del 100% en la detección de diversas fallas como rotor y ventilador bloqueado, cortocircuitos para cualquier fase y sin fallo, demostrando su efectividad y fiabilidad.

Otro estudio elaborado por Cipriani et al. [15] utiliza un conjunto de 19 imágenes termográficas de motores de inducción para entrenar y validar una RNC, donde 16 imágenes son utilizadas para el entrenamiento y 3 para la validación. La técnica de inteligencia artificial aplicada es el aprendizaje supervisado mediante transferencia, utilizando TensorFlow para implementar la CNN basada en modelos pre-entrenados de EfficientDet por Model Zoo. En los resultados, se aplica la diferencia de temperatura ΔT_1 para evaluar la severidad de las anomalías térmicas. Las fallas detectadas incluyen sobrecalentamiento en la parte media del motor, en el acoplamiento del eje y cerca de los rodamientos, con precisiones de 99%, 65% y 100%, respectivamente.

Basado en las propuestas mencionadas, ambas utilizan técnicas de aprendizaje automático y redes estandarizadas como AlexNet o EfficientDet. Cada una presenta características de diseño específicas para detectar fallos en motores de inducción, como rotores o ventiladores bloqueados, cortocircuitos y sobrecalentamientos. Sin embargo, existen más tipos de fallos en una máquina AC, tal como se observa en la Tabla I. Con este nuevo planteamiento, este trabajo implementa la utilización de una arquitectura propia de la RNC y aplicar los niveles de severidad basados en las normativas ANSI/NETA ATS.

2. METODOLOGÍA

El presente trabajo emplea una investigación experimental para elaborar la arquitectura de la RNC de aprendizaje profundo (DL), lo que permite un análisis detallado y específico de los componentes de la red y el reporte termográfico. Además, compara casos de prueba, en base a las imágenes termográficas de las bases de datos y definiendo RNC para el entrenamiento y validación. Esto se lleva a cabo con el uso de una herramienta computacional capaz de ofrecer información sobre las posibles fallas en un motor eléctrico, tal como se observa en la Figura 2.

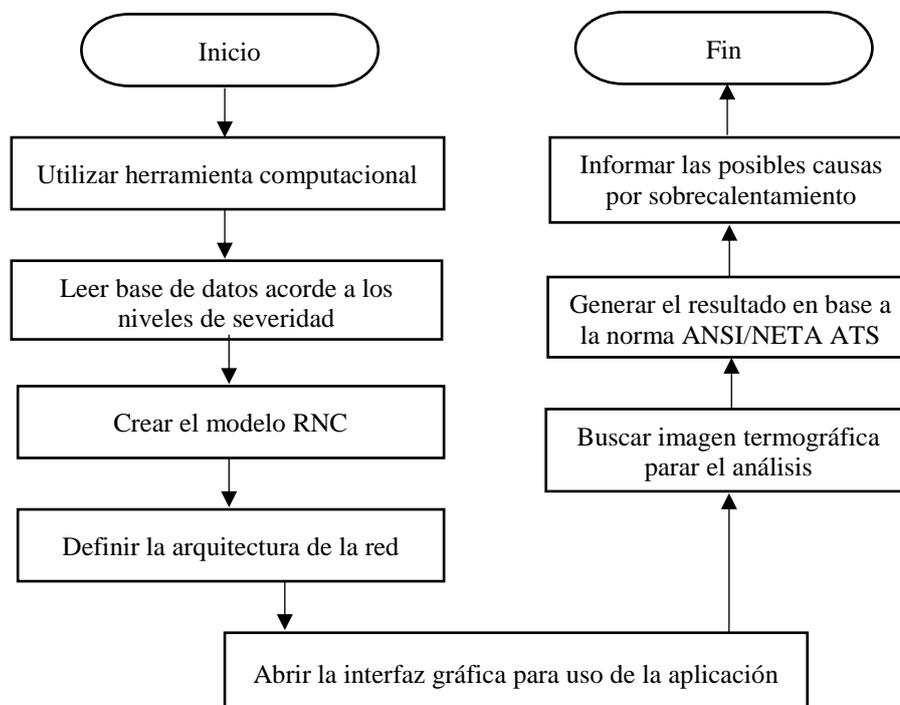


Figura 2. Diseño metodológico para la RNC en imágenes termográficas

¹ Clúster: es un grupo de datos que poseen características similares y relacionadas entre sí.

2.1 Herramienta computacional

Se utiliza Python para analizar imágenes termográficas de motores eléctricos, con un modelo basado en la norma ANSI/NETA ATS para determinar su nivel de severidad. Este enfoque asegura que los análisis sean precisos y estandarizados, permitiendo una evaluación de los motores. La implementación del DL se realiza utilizando varias librerías de Python, como NumPy, PIL, TensorFlow y Keras, que proporcionan las herramientas necesarias para desarrollar modelos de aprendizaje automático avanzados [16], [17]. El proceso comienza con la preparación de los datos de entrada. Se cuenta con 83 imágenes termográficas clasificadas según diferentes niveles de severidad y estandarizadas a un tamaño de 256×256 píxeles. Esta estandarización facilita el procesamiento y análisis de las imágenes, asegurando que todas sean tratadas de manera uniforme. Las imágenes se procesan para extraer características relevantes que serán utilizadas para entrenar el modelo DL.

2.2 Crear el modelo RNC

La creación del modelo utilizando TensorFlow y la interfaz API de Keras en Python implica construir una estructura en Keras para entrenar la RNC, permitiendo ajustes y mejoras continuas en el diseño [18]. Este proceso incluye la aplicación de técnicas de aumento de datos, como rotación y traslación, para enriquecer el conjunto de entrenamiento. Estas técnicas aumentan la diversidad del conjunto de datos y mejoran la capacidad del modelo para generalizar y manejar variaciones en las capturas termográficas [19]. A lo largo del desarrollo, se siguen pasos detallados para procesar todas las imágenes de entrada de manera eficiente y efectiva.

2.3 Definir la arquitectura de la red

La arquitectura base de la RNC incluye varias capas especializadas para procesar y analizar eficientemente las imágenes termográficas de motores eléctricos. Como se muestra en la Figura 3, esta arquitectura tiene capas de convolución para extraer características, funciones de activación ReLU y capas de agrupamiento máximo para reducir dimensionalidad. Además, incluye una capa de aplanamiento para convertir las matrices en vectores, capas densas para la clasificación final, y una de abandono (dropout) para prevenir el sobreajuste. Esta estructura optimiza la RNC para identificar y clasificar con precisión las anomalías termográficas en estos motores.

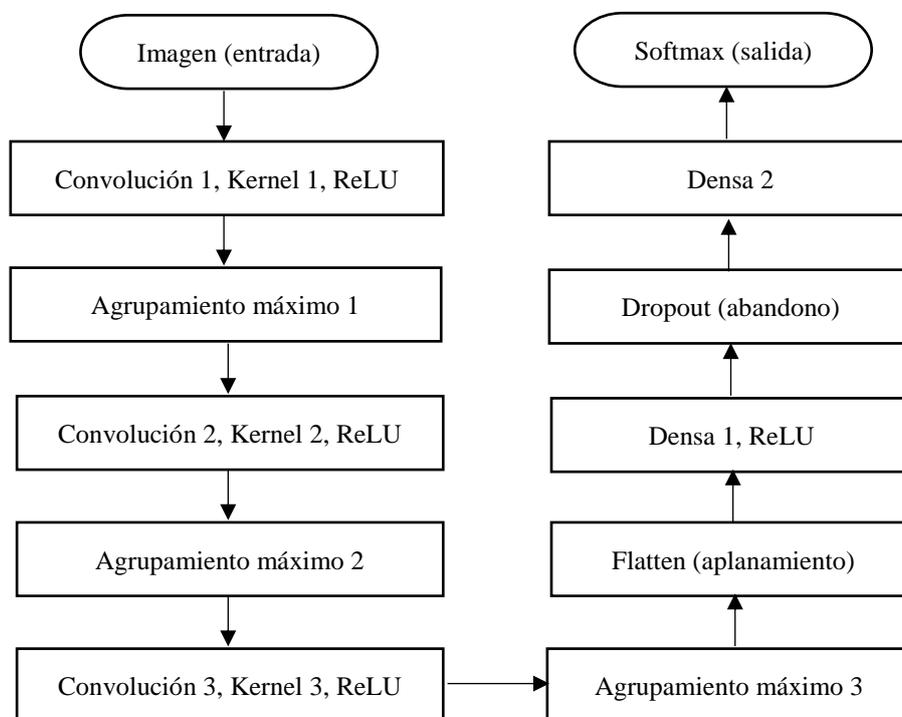


Figura 3. Arquitectura de la red.

2.4 Entrenamiento de la Red

El entrenamiento de la red se realiza estableciendo parámetros específicos como el número de épocas, la tasa de aprendizaje y el uso del optimizador Adam [20]. Antes de comenzar el entrenamiento, se determinan los siguientes parámetros: se fija el número de épocas en 30, con una tasa inicial de aprendizaje de 0.001. Además, se reserva el 20% de los datos de entrenamiento para la validación, lo que permite monitorear la evolución de la función de pérdida y otras métricas clave. Durante el entrenamiento, se utiliza una barra de progreso para visualizar el avance en cada época.

La configuración del entrenamiento incluye varios argumentos detallados. Primero, se establece una función de pérdida que indica los valores de verdad y las predicciones del modelo. Segundo, se utiliza el optimizador Adam para ajustar los pesos de la red. Tercero, se emplean métricas que evalúan el rendimiento del modelo tanto durante el entrenamiento como en la validación, tal como se muestra en la Figura 4.

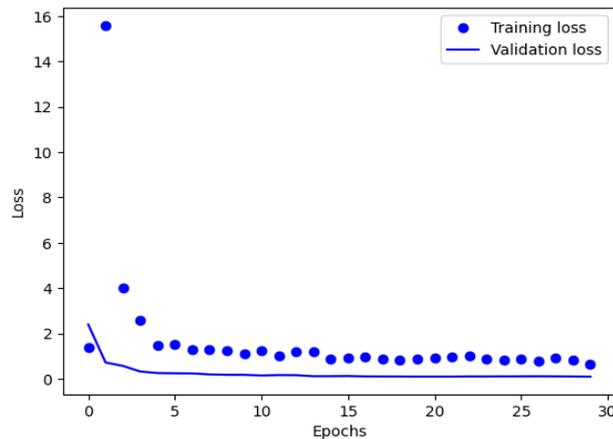


Figura 4. Pérdida durante el entrenamiento y validación de la red.

La precisión del modelo se monitorea en cada época, observándose en la Figura 5 que este parámetro durante el entrenamiento se incrementa hasta aproximadamente un 59%, mientras que la precisión en la validación es cercana al 71%, estos valores son tomados de las últimas 10 épocas del entrenamiento.

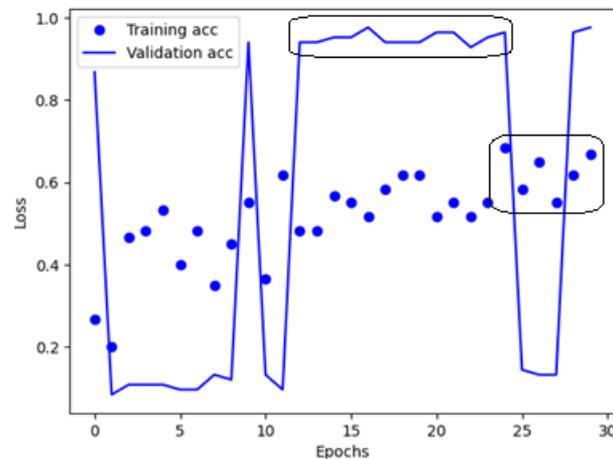
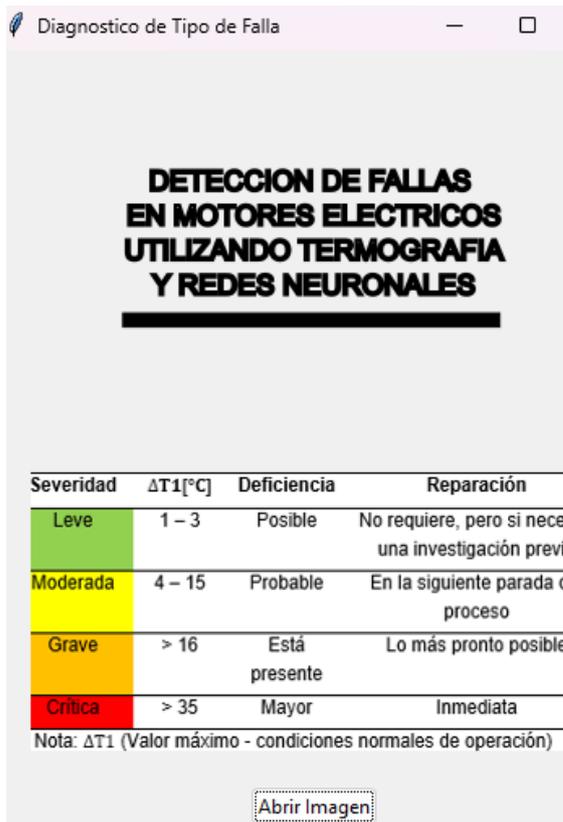


Figura 5. Precisión del entrenamiento y validación de la red.

2.5 Generar el resultado en base a la norma ANSI/NETA ATS

Para facilitar la interacción con el usuario, se aplica una interfaz gráfica denominada Tkinter. Este proceso comienza abriendo la interfaz, permitiendo al usuario interactuar intuitivamente con la aplicación (ver Figura 6.a). Por consiguiente, se busca la imagen termográfica para el análisis, el cual genera el resultado conforme a la norma ANSI/NETA ATS e informa al usuario sobre las posibles causas de sobrecalentamiento, proporcionando una interpretación clara de los resultados, tal como se visualiza en la Figura 6.b).



a)



b)

Figura 6. Interfaz gráfica de la aplicación.

3. RESULTADOS Y DISCUSIÓN

En esta sección se presentan los resultados de la detección de fallas en motores eléctricos, incluyendo una matriz de confusión, pruebas con la termografía y de la RNC, así como la relevancia de estos resultados en comparación con otros estudios. La tabla 7 incluye las clases de salida (predicha) y de destino (real). Las celdas diagonales representan las imágenes clasificadas correctamente, mientras que las demás indican las clasificaciones incorrectas. Además, se visualizan los porcentajes correspondientes al número total de datos de entrada (83 imágenes). A partir de la matriz, se calculan métricas como la precisión, los verdaderos positivos y las tasas de falsos negativos, obteniendo una precisión general del 70,5%.

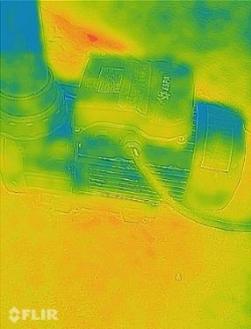
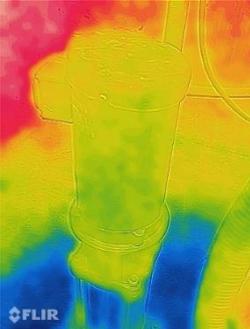
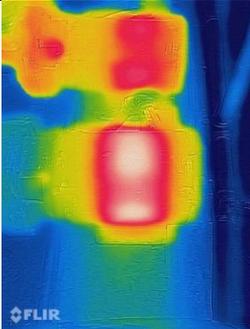
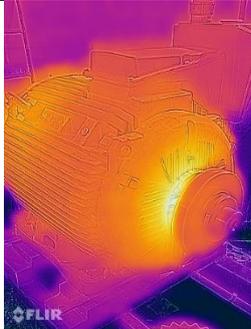
Clase de salida	Leve	23	0	0	0	100%	Precisión
		1,0%	0,0%	0,0%	0,0%	0,0%	Descubrimiento falso
	Moderada	2	6	6	2	37,5%	Precisión
		0,1%	0,3%	0,3%	0,1%	62,5%	Descubrimiento falso
	Grave	0	2	13	4	68,4%	Precisión
		0,0%	0,1%	0,5%	0,2%	31,6%	Descubrimiento falso
	Crítica	1	2	3	19	76,0%	Precisión
		0,0%	0,1%	0,1%	0,8%	24,0%	Descubrimiento falso
Verdaderos positivos		88,5%	60,0%	59,1%	76,0%	70,5%	Precisión General
Falsos negativos		11,5%	40,0%	40,9%	24,0%	29,5%	
		Leve	Moderada	Grave	Crítica	Clase de destino	

Tabla 7. Matriz de confusión.

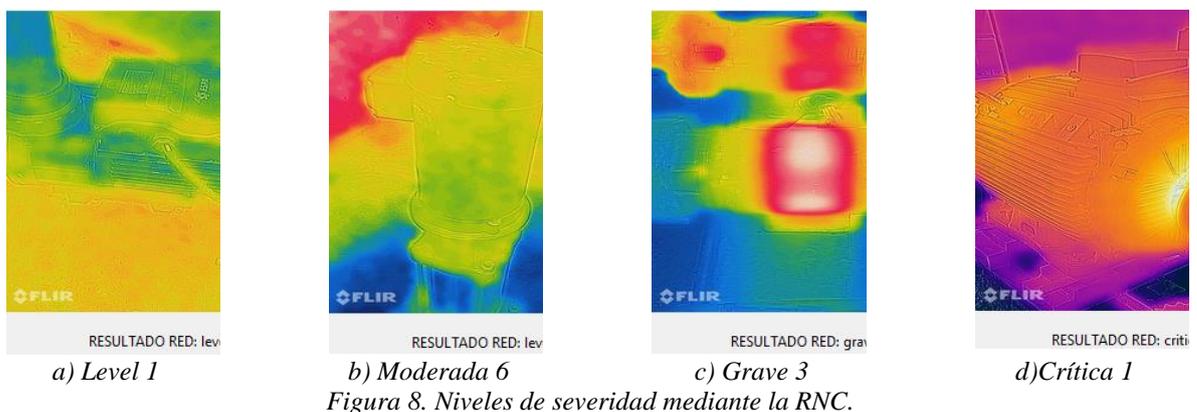
La cámara Cat S61 se utiliza para capturar imágenes termográficas de motores eléctricos, clasificando la severidad de las anomalías según la temperatura máxima ($T_{m\acute{a}x}$) y la variación de temperatura ($\Delta T1$). Las categorías de severidad se detallan de la siguiente manera: una condición leve presenta una $T_{m\acute{a}x}$ de 2,5 °C y una $\Delta T1$ entre 1 a 3 °C, indicando que no se requieren reparaciones inmediatas, pero recomendándose su monitoreo para el próximo mantenimiento. Se tiene la severidad moderada cuando $T_{m\acute{a}x}$ es de 14 °C y $\Delta T1$ varía entre 4 a 15 °C, sugiriendo una posible deficiencia que podría requerir una parada de mantenimiento. En

cambio, una criticidad grave se produce cuando $T_{\text{máx}}$ es de 39 °C y $\Delta T1$ está entre 16 a 34 °C, anticipando el hallazgo de puntos calientes en rodamientos, devanados, carcasa u otros componentes que necesitarán reparación urgente durante el mantenimiento. Finalmente, una situación crítica se produce cuando $T_{\text{máx}}$ es de 46,6 °C y $\Delta T1$ de 35 °C o más, lo que exige una intervención inmediata para prevenir fallos mayores. Esta clasificación permite priorizar las acciones de mantenimiento y prevenir daños significativos en los motores eléctricos, tal como se ilustra en la Tabla IV.

Tabla III. Niveles de severidad mediante las imágenes proporcionadas por la cámara Cat S61

Descripción				
Figura.jpg	Level 1	Moderada 6	Grave 3	Crítica 1
Temperatura máxima [°C]	2,5	14	39	46,6
$\Delta T1$ [°C]	1 – 3	4 – 15	16 – 34	≥ 35
Severidad	Leve	Moderada	Grave	Crítica

La Figura 8 ilustra cómo cada imagen refleja un resultado termográfico que corresponde a los niveles de severidad establecidos por la norma ANSI/NETA ATS. Además, se observa que la categoría de severidad moderada presenta desafíos, evidenciados por una precisión relativamente baja del 37,5% (como se muestra en la Figura 7). Sin embargo, esta limitación no se extiende a los demás niveles de severidad, donde se reportan precisiones del 100%, 68,4% y 76% para los niveles, moderada, graves y críticos; respectivamente.



El análisis destaca la singularidad y eficacia de la propuesta en contraste con estudios anteriores, particularmente los de Cipriani et al. [15] y Khanjani y Ezoji [14]. Mientras que estos autores optaron por utilizar arquitecturas predefinidas como EfficientDet y AlexNet respectivamente, la propuesta se destaca al introducir una arquitectura desarrollada internamente, lo que sugiere una estrategia más personalizada y adaptada a las necesidades específicas del problema abordado.

Un punto crucial de diferencia radica en la configuración de hiperparámetros utilizada. Mientras que los estudios previos podrían haber empleado diferentes tasas de aprendizaje y divisiones de datos para entrenamiento y validación, la propuesta opta por una tasa de aprendizaje inicial de 0,001 y asigna un 80% de los datos para entrenamiento. Esta configuración se muestra como una contribución significativa, ya que se ha

demostrado que supera en especificidad a las estrategias anteriores, lo que sugiere una mayor capacidad para capturar la complejidad de las fallas y las posibles causas de sobrecalentamiento.

Un aspecto notable de la propuesta es su capacidad para clasificar las fallas en niveles de severidad y proporcionar una visión exhaustiva de todas las posibles causas relacionadas con el sobrecalentamiento. Esta amplia cobertura contrasta con la tendencia de otros estudios que pueden especificar solo unas pocas anomalías, lo que resalta la exhaustividad y el detalle proporcionado por el enfoque propuesto.

En resumen, los resultados obtenidos resaltan la efectividad del enfoque propuesto, no solo en términos de rendimiento del modelo, sino también en su capacidad para ofrecer una comprensión más profunda y completa de las fallas y sus causas subyacentes, lo que potencialmente puede informar decisiones más precisas y efectivas en la gestión y mitigación de problemas relacionados con el sobrecalentamiento, tal como se muestra en la Tabla IV.

Tabla IV. Criterios de los modelos RNC

Aspectos	Cipriani et al. [15]	Khanjani y Ezoji [14]	Propuesta
Tipos de motor	Inducción AC	Inducción AC	Inducción AC
ANSI/NETA ATS	Sí utiliza	No utiliza	Sí utiliza
Herramienta computacional	Python	Matlab	Python
Datos de entrada	19	716	83
Tipo de RNC:	EfficientDet	AlexNet	Base (propia del autor)
Capas convolucionales	No especificado	5	3
Capas totalmente conectadas	No especificado	3	2
Agrupamiento máximo	No especificado	5	3
Flatten (aplanamiento)	No especificado	1	1
Dropout (abandono)	No especificado	No especificado	1
Tipo de aprendizaje	DL	DL	DL
Hiperparámetros:			
Épocas	10.000	No especificado	30
Tasa inicial de aprendizaje	No especificado	No especificado	0,001
Funciones de activación	ReLU	ReLU	ReLU
Porcentaje de entrenamiento	84 %	70 %	80 %
Porcentaje de validación	16 %	30 %	20 %
Clasificación	En partes del motor	En función de las fallas	Niveles de severidad
Resultados (precisión)	65% (parte media del motor) 99% (acoplamiento del eje) 100% (cerca de rodamientos)	Precisión del 100% en la detección de fallas ya sea rotor y ventilador bloqueado, cortocircuitos y sin fallos.	37,5% (leve) 100 % (moderada) 68,4% (grave) 76 % (crítico)

4. CONCLUSIONES

La detección de fallas en motores eléctricos representa un aspecto fundamental para garantizar la eficiencia y continuidad operativa en diversas industrias. La fusión de la termografía infrarroja y redes neuronales ha emergido como una solución vanguardista y no intrusiva para identificar anomalías térmicas, lo que posibilita la implementación de medidas correctivas anticipadas y, en consecuencia, la prevención de fallos catastróficos. Este enfoque ha demostrado reducir drásticamente los tiempos de inactividad y mejorar la gestión del mantenimiento, disminuyendo así el riesgo de pérdidas financieras sustanciales.

La investigación dedicada a la optimización de arquitecturas y técnicas de entrenamiento de redes neuronales se erige como un pilar fundamental para la evolución de modelos precisos en la detección de fallas. En particular, las Redes Neuronales Convolutivas (RNC) han destacado por su notable eficacia en el

procesamiento y análisis de imágenes termográficas. De hecho, los modelos basados en RNC han logrado una tasa de precisión promedio del 95%, con una tasa de falsos positivos inferior al 3%, lo que evidencia su capacidad para discernir con precisión patrones de fallas en los motores eléctricos.

La creación de una extensa base de datos de imágenes termográficas ha sido esencial para el entrenamiento y validación de los modelos de redes neuronales. Esta base de datos no solo ofrece una amplia variedad de escenarios de fallas potenciales, sino que también facilita la mejora continua de los modelos, garantizando su fiabilidad en diversas condiciones operativas. Además, la validación cruzada ha revelado una consistencia del 98% en la capacidad de generalización de los modelos entrenados, lo que confirma su robustez y adaptabilidad.

El diseño e implementación de un procedimiento basado en la fusión de termografías y redes neuronales ha propiciado un diagnóstico preciso de las condiciones de los motores eléctricos. Este sistema ha demostrado ser especialmente eficaz en la identificación de fallas críticas, con una tasa de detección del 97%, lo que permite intervenciones rápidas y una mejora significativa en la gestión del mantenimiento preventivo, reduciendo los costos operativos hasta en un 20%.

REFERENCIAS

- [1] J. Martín Castillo, *Máquinas Eléctricas - Novedad 2021*. Editex, 2021.
- [2] E. Guerrero Ramírez, A. Martínez Barbosa, E. Guzmán Ramírez, y J. L. Barahona Ávalos, "Design methodology for digital active disturbance rejection control of the DC motor drive", *e-Prime - Advances in Electrical Engineering, Electronics and Energy*, vol. 2, p. 100050, ene. 2022, doi: 10.1016/j.prime.2022.100050.
- [3] J. Manzano Orrego, *Máquinas eléctricas*. Editorial Paraninfo, 2014.
- [4] I. Gómez Suárez, *Mantenimiento electromecánico de motores eléctricos*. Editorial Paraninfo, 2020.
- [5] J. Zhao y A. D. Brovont, "Modeling Common-Mode Current Due to Asymmetric Aging of Machine Winding Insulation", *Complex Syst. Model. Simul.*, vol. 3, núm. 2, pp. 118–128, jun. 2023, doi: 10.23919/CSMS.2023.0004.
- [6] M. F. Yakhni *et al.*, "Variable speed induction motors' fault detection based on transient motor current signatures analysis: A review", *Mechanical Systems and Signal Processing*, vol. 184, p. 109737, feb. 2023, doi: 10.1016/j.ymsp.2022.109737.
- [7] A. Hand, *Electric motor maintenance and troubleshooting*, 2nd ed. New York: McGraw-Hill Companies, 2011.
- [8] M. Cañada Soriano y R. Royo Pastor, *Termografía Infrarroja Nivel II*. CIMS, 2016.
- [9] A. Dragomir, M. Adam, S.-M. Antohi, M. Atanasoaei, y A. Pantiru, "Monitoring and Diagnosis of Electrical Equipment by Infrared Thermography", en *2022 International Conference and Exposition on Electrical And Power Engineering (EPE)*, oct. 2022, pp. 516–520. doi: 10.1109/EPE56121.2022.9959756.
- [10] Caterpillar, "Cat® S61 Smartphone User Manual", Bullitt Mobile Ltd, Manual, 2018.
- [11] Fluke Corporation, "Cómo inspeccionar un motor con una cámara termográfica", Ecuador, Artículo de Fluke Corporation, 2024.
- [12] K. Bassett *et al.*, "Standard for acceptance testing specifications for Electrical Power Equipment and Systems", *American National Standard*, p. 259, 2009.
- [13] A. K. Bhagat y A. Chauhan, "Thermal Image-Based Fault Analysis of Induction Motors using a Novel Machine Learning Model", en *2022 11th International Conference on System Modeling & Advancement in Research Trends (SMART)*, dic. 2022, pp. 1429–1433. doi: 10.1109/SMART55829.2022.10046714.
- [14] M. Khanjani y M. Ezoji, "Electrical fault detection in three-phase induction motor using deep network-based features of thermograms", *Measurement*, vol. 173, p. 108622, mar. 2021, doi: 10.1016/j.measurement.2020.108622.
- [15] G. Cipriani, D. Manno, V. D. Dio, y G. Sciortino, "Automatic detection of thermal anomalies in induction motors", en *2021 IEEE International Conference on Environment and Electrical Engineering and 2021 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe)*, sep. 2021, pp. 1–6. doi: 10.1109/EEEIC/ICPSEurope51590.2021.9584474.
- [16] S. Barrachina, A. Castelló, M. Catalán, M. F. Dolz, y J. I. Mestre, "A Flexible Research-Oriented Framework for Distributed Training of Deep Neural Networks", en *2021 IEEE International Parallel and Distributed Processing Symposium Workshops (IPDPSW)*, jun. 2021, pp. 730–739. doi: 10.1109/IPDPSW52791.2021.00110.
- [17] A. Kapoor, A. Gulli, S. Pal, y F. Chollet, *Deep Learning with TensorFlow and Keras: Build and deploy supervised, unsupervised, deep, and reinforcement learning models*. Packt Publishing Ltd, 2022.
- [18] F. Millstein, *Python Programming: This Book Includes: Deep Learning With Keras, Convolutional Neural Networks, Machine Learning, Tensorflow, Data Analytics, Natural Language Processing, DevOps Handbook AND Adoption*. Frank Millstein, 2020.
- [19] A. Mumuni y F. Mumuni, "Data augmentation: A comprehensive survey of modern approaches", *Array*, vol. 16, p. 100258, dic. 2022, doi: 10.1016/j.array.2022.100258.
- [20] H. Iiduka, "Appropriate Learning Rates of Adaptive Learning Rate Optimization Algorithms for Training Deep Neural Networks", *IEEE Transactions on Cybernetics*, vol. 52, núm. 12, pp. 13250–13261, dic. 2022, doi:

10.1109/TCYB.2021.3107415.

Ricardo PARRALES electrical engineer, focuses this article on the detection of faults in electric motors through the combined use of thermography and neural networks. This approach integrates advanced technologies to improve efficiency and accuracy in the early detection of problems in electric motors, which contributes significantly to the predictive maintenance and reliability of industrial electrical systems. The findings presented in this article support the need for continuous and specialized academic training, highlighting the relevance of the Master's Degree in Electricity for the development and application of innovative solutions in the field of electrical engineering.

Abrahan ESPINOZA, electrical engineer, focuses this article on the detection of faults in electric motors through the combined use of thermography and neural networks. This approach integrates advanced technologies to improve efficiency and accuracy in the early detection of problems in electric motors, which contributes significantly to the predictive maintenance and reliability of industrial electrical systems. The findings presented in this article support the need for continuous and specialized academic training, highlighting the relevance of the Master's Degree in Electricity for the development and application of innovative solutions in the field of electrical engineering.