



TERMOGRAFÍA INFRARROJA PASIVA APLICADA A SISTEMAS DE DETECCIÓN DE FALLAS: UNA REVISIÓN.

PASSIVE INFRARED THERMOGRAPHY APPLIED TO FAULT DETECTION SYSTEMS: A REVISION

Espinoza-Del Angel Cinthia ¹, Femat-Díaz Aurora ^{1*}

¹ Facultad de Ingeniería, Universidad Autónoma de Querétaro, Cerro de las Campanas S/N Col. Las Campanas. Querétaro, México

* Autor de correspondencia, correo: : afemat@uaq.mx

Resumen

En este artículo se presenta una revisión de la metodología utilizada en termografía infrarroja pasiva como una herramienta de monitoreo de condición. El enfoque se establece a tres tipos de aplicaciones industriales, eléctrica, electrónica y mecánica. Se discuten conceptos básicos y los dispositivos en los que se ha aplicado, y se estudian los métodos más usados para mejorar la inspección utilizando análisis termográfico. El trabajo destaca los factores técnicos que afectan la calidad de la imagen, y el proceso de decisión del clasificador. También se presenta una comparación de los espacios de color, los métodos de reducción de características y los clasificadores más utilizados en los últimos años.

Palabras clave: *Análisis de fallas, imagen térmica, sistemas de fallas, termografía pasiva.*

Abstract

This article presents a review of the methodology used in passive infrared thermography as a condition monitoring tool. It focuses on three types of industrial applications, electrical, electronic, and mechanical. Basic concepts and the devices in which it has been applied are discussed, and the most used methods to improve inspection using thermographic analysis are studied. The work highlights the technical factors that affect image quality and the classifier's decision process. A comparison of color spaces, feature reduction methods, and classifiers most used in recent years is also presented.

Keywords: : Failure analysis, thermal image, fault detection systems, passive thermography.

1. Introducción

Los sistemas de detección de fallas permiten la ubicación e identificación del mal funcionamiento de un dispositivo o componente (Sanchez-Londono, 2021); en la industria se utilizan principalmente en aplicaciones eléctricas, electrónicas y mecánicas (Osornio-Rios et al., 2019). Su objetivo es evitar tiempos de inactividad no planificados y pérdidas financieras, por lo que es vital contar con un sistema eficiente para garantizar la calidad de los productos (Choudhary et al., 2021; Zhang y Fjeld, 2020). Los métodos tradicionales utilizan medición de parámetros eléctricos o de vibración (Glowacz y Glowacz, 2017; Rauber et al., 2021; Suguna et al., 2016; Wronkowicz, 2016).

En los últimos años se ha popularizado el uso de termografía infrarroja (TI) para el diagnóstico y monitoreo sin contacto, ya sea de materiales, componentes o equipos; lo que permite observar la distribución de temperatura con el objetivo de identificar áreas en donde existen problemas potenciales (Muralidhar y Reddy, 2014; Olivatti et al., 2018). Su principal aplicación radica en dispositivos donde el factor térmico es crucial para su desempeño y confiabilidad, como en componentes electrónicos, motores o transformadores. Esto debido a que el calor producido por cada dispositivo depende de la energía que consume (Ahmed et al., 2015), y cuando se genera en exceso advierte sobre inconvenientes (Maciel et al., 2017; Olivatti et al., 2018).

La TI ha demostrado ser eficiente en la detección de fallas, pero la precisión de la técnica depende del conocimiento y la capacitación del usuario en la interpretación de los datos de la imagen. Este artículo reúne contribuciones recientes de la termografía infrarroja pasiva para diversas aplicaciones eléctricas, electrónicas y mecánicas. También analiza la diferencia

entre los métodos más utilizados para clasificación, extracción y reducción de características. Con esto, el lector podrá identificar tendencias, oportunidades y desafíos para el desarrollo de sistemas que utilizan termogramas.

2. Termografía infrarroja

La termografía infrarroja utiliza una cámara mediante la cual se detecta la radiación emitida por un cuerpo (Ahmed et al., 2015; Kurukuru et al., 2019b). Su espectro se puede dividir en tres regiones de infrarrojo, cercano ($0,75 \mu\text{m}$ a $1,5 \mu\text{m}$), medio ($1,5 \mu\text{m}$ a $20 \mu\text{m}$) y lejano ($20 \mu\text{m}$ a $1000 \mu\text{m}$) (Bagavathiappan et al., 2013; Vollmer y Möllmann, 2018). Las cámaras térmicas suelen alcanzar un rango de $7,5 \mu\text{m}$ a $14 \mu\text{m}$, su función es convertir la cantidad de radiación en una aproximación a la temperatura del objeto que se muestra en una imagen llamada termograma (Gyorok y Beszedes, 2019; Liu y Jiang, 2013; Olivatti et al., 2018; Wronkowicz, 2016).

La TI se puede clasificar en activa y pasiva (Kimande et al., 2021; Sanati et al., 2018). La activa utiliza un estímulo externo para generar calor en un objeto que no puede producirlo, y se usa para conocer la degradación de un material (Aghaei et al., 2015; Salazar y Macabebe, 2016). Las técnicas más populares para producir este estímulo son inducción, vibración, fase pulsada y corriente parásita (Aghaei et al., 2015; Vollmer y Möllmann, 2018). El proceso para el uso de la termografía activa se muestra en la Figura 1, donde se puede ver que se aplica una fuente de calor externa sobre el objeto y se mide la radiación emitida por este con la cámara, para luego identificar los defectos en la pieza inspeccionada a través de técnicas de procesamiento de imágenes.




Figura 1. TI activa para la detección de degradación en materiales (Elaboración propia). Imagen térmica por Prc1333 (Prc1333, 2010).

En el modo pasivo, el dispositivo de investigación genera calor por conducción, convección o por radiación, y la termografía

se utiliza para monitorear su funcionamiento, como se observa en la Figura 2 (Alajmi et al., 2019; Olivatti et al., 2018).




Figura 2. TI pasiva para el monitoreo de condición de un dispositivo que funciona con corriente eléctrica (Elaboración propia). Imagen térmica por OzAdrian (OzAdrian, 2012).

En ambos tipos de termografía se puede realizar análisis cualitativo y cuantitativo. En el cualitativo se comparan dos imágenes para localizar anomalías; una pertenece al objeto con falla, y la otra al objeto en condiciones normales. En el cuantitativo, la medida de temperatura representada en la imagen se utiliza como criterio para determinar la gravedad de un problema y así establecer un diagnóstico (Jadin et al., 2014; Lopez-Perez y Antonino-Daviu, 2017; Redon et al., 2017).

3. Aplicaciones industriales de la TI pasiva para el diagnóstico y monitoreo de fallas

La TI pasiva se ha utilizado en aplicaciones eléctricas tales como instalaciones residenciales e industriales (Dutta et al., 2016; Kostic et al., 2021; Palimkar y Bhole, 2016), reóstatos (Dutta et al., 2019), transformadores (Kimande et al., 2021; Maciel et al., 2017; Wang y Zhao, 2019), subestaciones (Ullah et al., 2017), pararrayos (Novizon y Abdul-Malek, 2016) y líneas de transmisión (Hui y Fuzhen, 2015; Kim et al., 2021). En estos trabajos se han identificado pérdidas de energía por aislamiento inadecuado, puntos calientes, sobrecargas, conexiones defectuosas, entre otros. Otra aplicación es el uso de paneles solares, donde se ha utilizado para observar la degradación y ubicación de puntos calientes (Gallardo-saavedra et al., 2019; Kumar et al., 2017; Niazi et al., 2019). En el campo de las aplicaciones electrónicas se han

realizado pocos estudios, la principal aplicación ha sido en componentes montados en placas de circuito impreso (PCB, por sus siglas en inglés) (Al-Obaidy et al., 2017b; Laxmi, 2021; Petrosyants et al., 2016). En estas se ha medido la radiación emitida por circuitos integrados (Akole y Kulkarni, 2016; Al-Obaidy, 2016; Andonova et al., 2014), diodos (Stoynova et al., 2018), transistores (Chen et al., 2018), y condensadores (Mahfurdz et al., 2020; Sun et al., 2019). Se detectaron cortocircuitos, polaridad inversa, componentes faltantes, sobretensión y defectos de PCB (Alaoui et al., 2019; Sarawade y Charniya, 2019).

En las aplicaciones mecánicas sus usos más comunes son la identificación de fallas en motores de inducción, como desequilibrio, desalineación o lubricación inadecuada del rodamiento, sobrecarga o anillo de jaula de ardilla defectuoso (Choudhary et al., 2021; Glowacz et al., 2017; Khamisan et al., 2015; Resendiz-Ochoa et al., 2020; Sanchez-Londono, 2021). También se ha aplicado en radiadores para localizar condiciones como aletas obstruidas, conexión floja entre aletas y tubos, falla de la puerta del radiador y fugas de refrigerante (Taheri-Garavand et al., 2015). Otro componente que se ha analizado es el rotor, detectando defectos como desalineación del eje, desbalance del acoplamiento y aflojamiento de la base (Duan et al., 2016). Por último, se ha utilizado en motores de corriente continua (CC) para identificar cortocircuitos y desgaste de engranajes (Glowacz y Glowacz, 2016).

4. Metodología de los sistemas de detección de fallas basados en TI

En general, la metodología de un sistema de detección de fallas implica las siguientes etapas, adquisición de

imágenes, preprocesamiento, extracción de características, y un método de clasificación, como se muestra en la Figura 3.




Figura 3. Diagrama de flujo del sistema de detección basado en TI (Elaboración propia).

4.1. Adquisición de imágenes

La calidad de las imágenes depende de diversos factores, los principales son la cámara, la distancia de captura y la emisividad. La elección de la cámara debe hacerse en función del rango de temperatura del dispositivo a monitorear (FLIR Systems Inc., 2018). La distancia entre el objeto y la cámara se relaciona con la resolución y la precisión de la medición (Nunak et al., 2015; Playà-Montmany y Tattersall, 2021). Para determinarla se calcula el campo de visión instantáneo

(IFOV, por sus siglas en inglés), con el objetivo de establecer el tamaño del objeto más pequeño que puede ser detectado. El IFOV se representa como una proyección angular de un único pixel, como se muestra en la Figura 4, y se calcula con la Ecuación 1, donde d es el tamaño del detector y f es el ángulo focal. Una vez que se ha especificado, se utiliza la Ecuación 2 para calcular el tamaño más pequeño que puede medirse (Dziarki et al., 2019; FLIR Systems Inc., 2016, 2018b; Gyorok y Beszedes, 2019).




Figura 4. Representación del campo de visión instantáneo (Elaboración propia).

$$IFOV = 2 * \arctan \left(\frac{d}{2 * f} \right) \quad [1]$$

$$IFOV [mm] = \left(\frac{IFOV}{1000} \right) \text{ distancia al objetivo} \quad [2]$$

Un aspecto fundamental que hay que considerar es la emisividad (ϵ), esta define la relación entre dos radiaciones, una proveniente de la superficie ($N_{\lambda T}$) y

la otra del objeto (E_b). Se evalúa con la Ecuación 3 y su valor se establece en un rango de 0 a 1, depende del material, la longitud de onda, el ángulo y la dirección del campo de visión (Akole y Kulkarni, 2016; Rakrueangdet et al., 2016; Vollmer y Möllmann, 2018). Cuando se tiene una emisividad igual a 1, el objeto se considera un radiador perfecto o cuerpo negro. Para tener una medición de temperatura precisa la emisividad debe

compensarse [Resendiz-Ochoa et al., 2018], algunos métodos utilizados para reducirla son la aplicación de cinta, pintura o líquido corrector blanco [Mamchur et al., 2020; Wargulski et al., 2020]. En ningún caso el valor de emisividad debe tomarse como constante [Pavel et al., 2019].

$$\varepsilon = \left(\frac{N_{\lambda T}}{E_b} \right) \quad [3]$$

4.2. Preprocesamiento de imágenes

Esta etapa tiene como objetivo preparar el contenido de la imagen para la extracción de características. Las técnicas más utilizadas en el análisis termográfico son la conversión entre espacios de color, filtros para reducir el ruido, métodos para mejorar el contraste y la nitidez de la imagen, y la segmentación de la región de interés (ROI, por sus siglas en inglés).

Tras la captura de las imágenes térmicas se puede presentar ruido que afecta la calidad y precisión de los datos cuantitativos [Aghaei et al., 2015]. Para suprimir estas frecuencias se utilizan técnicas de filtrado como gaussiano, conservación de bordes, mediana, Wiener y combinación de bloques. El filtro gaussiano es usado para eliminar efectos de ruido específicos, pero reduce la nitidez de la imagen. El filtro de conservación de bordes suaviza la apariencia de la imagen y reduce el desenfoque en los bordes [Alajmi et al., 2019]. El filtro de mediana se utiliza por su eficacia para eliminar ruido "sal y pimienta" [Al-Obaidy et al., 2017a; Pal et al., 2018]. El filtro Wiener se aplica para ruido aditivo y desenfoque de la imagen. Finalmente, la combinación de bloques y filtrado 3-D (BM3D, por sus siglas en inglés) elimina ruido sal y pimienta y efectos de desenfoque. [Al-Obaidy et al., 2017a,b].

Un estudio realizado por Al-Obaidy et al. evaluó el rendimiento de diferentes métodos de reducción de ruido. Se tomaron como referencia los factores de relación pico señal/ruido (PSNR, por sus siglas en inglés) y relación señal/ruido (SNR, por sus siglas en inglés), determinando que los filtros de mediana y BM3D son los que obtienen el mejor rendimiento [Al-Obaidy et al., 2017a]. La SNR se puede determinar usando la Ecuación 4, donde P_s es la potencia de la señal y P_n es la potencia del ruido [Sanati et al., 2018].

$$SNR = \left(\frac{P_s}{P_n} \right) \quad [4]$$

Una vez mejorada la calidad de la imagen hay que seleccionar un espacio de color. Estos son una especificación de un sistema de coordenadas en el que cada color está representado por un único punto contenido en su interior, como se aprecia en la Figura 5 [Gonzalez y Woods, 2008]. Su propósito es facilitar y estandarizar la forma en la que se representa el color en una aplicación específica. Hay varios espacios de color como RGB (Red, Green y Blue); HSI (Hue, Saturation y Intensity); HSV (Hue, Saturation y Value); CMY (Cian, Magenta y Yellow) y CIE L*a*b (Commission Internationale de l'Éclairage L*a*b). Las siglas de los cuatro primeros provienen del inglés y las del último en francés [Khamisan et al., 2015; Rhyne, 2017].

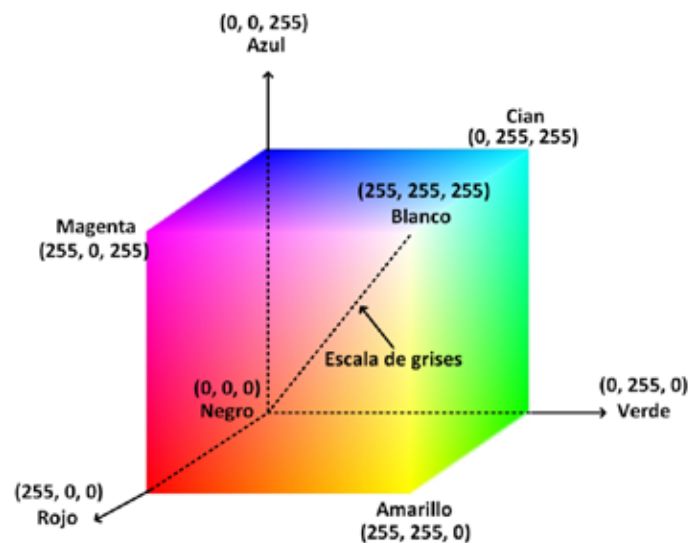


Figura 5. Representación matemática del espacio de color RGB [Elaboración propia].

Las cámaras termográficas obtienen imágenes RGB de forma predeterminada, algunos autores mantienen este formato porque lo consideran ideal para extraer características de una imagen termográfica [Akole y Kulkarni, 2016; Chellamuthu y Sekaran, 2019; Khamisan et al., 2015]. Otros justifican el uso de la escala de grises para crear algoritmos más rápidos, pero en esta transformación la pérdida de información debe ser considerada por la conversión de tres canales a uno [Kurukuru et al., 2019b; Resendiz-Ochoa et al., 2020]. También se ha empleado el espacio CMY, pero no se justificó su uso [Glowacz y

Glowacz, 2016, 2017). Los espacios HSI, HSV y CIE L*a*b se han utilizado porque aproximan los colores a los que la visión humana puede apreciar (Al-Musawi et al., 2020; Haider et al., 2018; Mahfurdz et al., 2020). De los modelos anteriores, el espacio RGB y la escala de grises son los más utilizados (Al-Musawi et al., 2020; Dutta et al., 2016; Huda y Taib, 2013a, b; Hui y Fuzhen, 2015; Kurukuru et al., 2019b).

Después de elegir un espacio de color, se procede a la extracción de la ROI para seleccionar el área con mayor distribución de temperatura. Esto se puede hacer separando el primer plano de la imagen del fondo, agrupando los píxeles de acuerdo a su similitud de color, o por la forma de los componentes (Palimkar y Bhole, 2016; Schuss et al., 2021). Las técnicas de segmentación más utilizadas son Otsu, Roberts, Prewitt, Canny y Sobel (Dutta et al., 2016; Haider et al., 2018; Kurukuru et al., 2019b). De estas, el método de Otsu calcula el umbral óptimo para separar los píxeles en dos clases, considerando la máxima desviación estándar entre las clases (Hinojosa et al., 2018) y los otros delimitan los bordes del objeto de interés para separarlo del resto (Kurukuru et al., 2019b). En 2016, Dutta et al. compararon los métodos de Otsu, Roberts, Prewitt y Sobel basándose en las métricas del error cuadrático medio (MSE, por sus siglas en inglés) y la PSNR, concluyeron que de los cuatro Sobel y Otsu son los que mejor se desempeñan (Dutta et al., 2016). Por otro lado, Duan y colaboradores demostraron que si no se considera la segmentación de la ROI se puede perder hasta un 6% de la precisión (Duan et al., 2016).

4.3. Extracción de características

En el análisis térmico cuantitativo, a partir de la extracción de características se identifica el estado o condición del dispositivo. (Khamisan et al., 2015) Para esto se pueden utilizar métodos matemáticos de álgebra lineal, operaciones aritméticas, lógica binaria, geometría, ecuaciones diferenciales, probabilidad, estadística, etc. (Gonzalez y Woods, 2008).

Muchas investigaciones utilizan descriptores estadísticos de primer y segundo orden, como media, desviación estándar, asimetría, curtosis, entropía y energía (Dutta et al., 2019; Hui y Fuzhen, 2015; Novizon y Abdul-Malek, 2016; Resendiz-Ochoa et al., 2020).

Otra forma de extraer características es identificando relaciones espaciales entre los niveles de color de los píxeles de la imagen, a través de la matriz de co-ocurrencia. A partir de esta última se calculan parámetros como contraste, correlación, homogeneidad y entropía (Huda y Taib, 2013a; Kurukuru et al., 2019a,b; Liu et al., 2019).

4.4. Reducción de características

En este proceso se seleccionan las características más relevantes relacionadas con la falla del dispositivo. Se recomienda utilizar tres como máximo porque un número mayor puede provocar un algoritmo lento y pérdida de precisión en el clasificador (Al-Obaidy et al., 2017; Dutta et al., 2019).

El método más utilizado para reducir la dimensión de las variables es el análisis de componentes principales (ACP). Es una técnica multivariante que permite transformar un conjunto de variables en componentes no correlacionados, los cuales son ordenadas en función de su varianza (Mehta et al., 2021; Ng, 2017; Shereena y David, 2015). Otro método comúnmente utilizado es el análisis discriminante lineal (LDA, por sus siglas en inglés) (Choudhary et al., 2021; Mehta et al., 2021; Resendiz-Ochoa et al., 2020). En este la selección se obtiene maximizando la varianza entre clases y minimizando la distancia dentro de ellas (Anaya-Isaza et al., 2016; Shereena y David, 2015; Tharwat et al., 2017). Estudios comparativos entre ambas técnicas han concluido que el ACP funciona mejor para reducir dimensiones y el LDA como clasificador (Anaya-Isaza et al., 2016; Shereena y David, 2015).

4.5. Algoritmo de clasificación

Un algoritmo de clasificación asigna una clase a un objeto en función de la correlación de sus características, su patrón de reconocimiento puede ser supervisado o no supervisado (Aujeszky et al., 2017; Sharma y Kaur, 2013). En el aprendizaje supervisado las funciones se aprenden del historial de datos y se asigna una etiqueta por una relación entre las variables de entrada y salida. En el no supervisado sólo se dispone de datos de entrada y su objetivo es incrementar el conocimiento estructural (Batta, 2020; Saravanan y Sujatha, 2018). Los métodos de clasificación más usados se basan en estadística, redes neuronales, árboles de decisión y máquinas de vectores

de soporte [Lo et al., 2019; Paolanti y Frontoni, 2020].

En los últimos años se ha observado una tendencia creciente en el uso de algoritmos de inteligencia artificial, el más explorado en el reconocimiento de patrones térmicos es la red neuronal artificial perceptrón multicapa (MLP, por sus siglas en inglés). Su rango de precisión está entre el 74,25% y el 97,84% [Jadin et al., 2015; Olivatti et al., 2018; Taheri-Garavand et al., 2015; Ullah et al., 2020]. Este clasificador obtiene un máximo rendimiento cuando se utiliza en combinación con un algoritmo genético (AG) para la reducción de características [Huda y Taib, 2013a; Taheri-Garavand et al., 2015].

La máquina de vector de soporte (SVM, por sus siglas en inglés) es el segundo método de clasificación más utilizado y puede tener un rango de precisión del 85,67% al 98,90% [Duan et al., 2016; Hui y Fuzhen, 2015; Mehta et al., 2021; Ullah et al., 2020; Yang et al., 2016;]. Estudios comparativos entre MLP y SVM han concluido que este último se desempeña mejor al otorgar una condición de falla, también demostró mejor desempeño que los clasificadores estadísticos Naive Bayes (NB) y k vecinos más cercanos (K-NN, por sus siglas en inglés) [Duan et al., 2016; Jadin et al., 2014; Olivatti et al., 2018; Umair et al., 2020]. Otros estudios mostraron que el sistema adaptativo de inferencia neuro-difusa (ANFIS, por sus siglas en inglés) y el bosque de decisión aleatorio (RDF, por sus siglas en inglés) eran superiores al SVM [Al-Obaidy et al., 2017b; Ullah et al., 2020].

Conclusiones

El uso de TI puede proporcionar información útil para garantizar la integridad y la confiabilidad de un dispositivo y evitar fallas prematuras en estos, pero es necesario que la técnica se aplique considerando diferentes características para ser eficaz y reproducible.

En la captura de la imagen, el análisis térmico puede ser influenciado por factores como el ángulo de visión instantáneo, el ajuste de la emisividad y la relación entre la selección de la cámara y los rangos de temperatura del objeto de estudio. Estos factores deben ser considerados antes de iniciar un proceso de identificación de fallas para evitar que la calidad de la imagen se vea afectada para su posterior análisis.

Para identificar patrones de comportamiento de fallas en imágenes térmicas, la elección del espacio debe estar justificada porque antecede a la extracción y selección de características en el proceso de identificación. Una vez determinado el modelo de color, se pueden utilizar métodos estadísticos para eliminar las variables irrelevantes del algoritmo de clasificación y así mejorar su precisión y rendimiento computacional.

El uso de técnicas de inteligencia artificial se ha convertido en un factor clave para el desarrollo de sistemas de detección de fallas, debido a su alta precisión de detección y aprendizaje autónomo. Sin embargo, para alcanzar su máximo rendimiento es importante considerar la reducción de variables de entrada y el uso de gran cantidad de datos para su implementación.

Agradecimientos

Los autores expresan su agradecimiento al Consejo Nacional de Ciencia y Tecnología (CONACYT) por financiar este trabajo a través del "Programa Nacional de Posgrados de Calidad (PNPC)" con la beca escolar 1033981.

Referencias bibliográficas

- Aghaei, M., Gandelli, A., Grimaccia, F., Leva, S., y Zich, R. E. (2015). IR real-time analyses for PV system monitoring by digital image processing techniques. *Proceedings of 1st International Conference on Event-Based Control, Communication and Signal Processing, EBCCSP 2015*, 1-6. <https://doi.org/10.1109/EBCCSP.2015.7300708>
- Ahmed, M. M., Huda, A. S. N., y Mat Isa, N. A. (2015). Recursive construction of output-context fuzzy systems for the condition monitoring of electrical hotspots based on infrared thermography. *Engineering Applications of Artificial Intelligence*, 39, 120-131. <https://doi.org/10.1016/j.engappai.2014.11.010>
- Akole, S. S., y Kulkarni, V. B. (2016). Thermal analysis of active electronic component with thermal imaging. *Association for Computing Machinery International Conference Proceeding Series*, 37, 1-6. <https://doi.org/10.1145/2905055.2905095>

- Al-Musawi, A. K., Anayi, F., y Packianather, M. [2020]. Three-phase induction motor fault detection based on thermal image segmentation. *Infrared Physics and Technology*, 104, 103140. <https://doi.org/10.1016/j.infrared.2019.103140>
- Al-Obaidy, F. [2016]. *IC Testing using thermal image Based on intelligent classification methods*. November 1999.
- Al-Obaidy, F., Yazdani, F., y Mohammadi, F. A. [2017]. Intelligent testing for Arduino UNO based on thermal image. *Computers and Electrical Engineering*, 58, 88-100.
- Al-Obaidy, F., Yazdani, F., y Mohammadi, F. A. [2017]. Fault detection using thermal image based on soft computing methods: Comparative study. *Microelectronics Reliability*, 2-10. <https://doi.org/10.1016/j.microrel.2017.02.013>
- Alajmi, M., Awedat, K., Aldeen, M. S., y Alwagdani, S. [2019]. IR thermal image analysis: An efficient algorithm for accurate hot-spot fault detection and localization in solar photovoltaic systems. *IEEE International Conference on Electro Information Technology*, 2019-May, 162-168. <https://doi.org/10.1109/EIT.2019.8833855>
- Alaoui, N. E. B., Cassou, A., Tounsi, P., Boyer, A., y Viard, A. [2019]. Using infrared thermal responses for PCBA production tests: Feasibility study. *Microelectronics Reliability*, 100-101(June), 113354. <https://doi.org/10.1016/j.microrel.2019.06.046>
- Anaya-Isaza, A. J., Peluffo-Ordoñez, D. H., Alvarado-Pérez, J. C., Ivan-Rios, J., Castro-Silva, J. A., Rosero-Montalvo, P. D., Peña-Unigarro, D. F., C., J. S.-C. A., y Umaquina-Criollo, A. C. [2016]. Estudio comparativo de métodos espectrales para reducción de la dimensionalidad: LDA versus PCA . Comparative study between spectral methods for dimension reduction LDA versus PCA. *INCISCOS 2016 International Conference on Information Systems and Computer Science, November*.
- Andonova, A., Angelov, G., y Chernev, P. [2014]. Diagnostics of packaged ICs By infrared thermography. *Proceedings of the 2014 37th International Spring Seminar on Electronics Technology*, ISSE 2014, 261-266. <https://doi.org/10.1109/ISSE.2014.6887605>
- Aujeszky, T., Korres, G., y Eid, M. [2017]. Thermography-based material classification using machine learning. *2017 IEEE International Symposium on Haptic, Audio and Visual Environments and Games (HAVE)*, 1-6. <https://doi.org/10.1109/HAVE.2017.8240344>
- Bagavathiappan, S., Lahiri, B. B., Saravanan, T., Philip, J., y Jayakumar, T. [2013]. Infrared thermography for condition monitoring - A review. *Infrared Physics and Technology*, 60, 35-55. <https://doi.org/10.1016/j.infrared.2013.03.006>
- Batta, M. [2020]. Machine Learning Algorithms: A Review. *International Journal of Science and Research (IJSR)*, 9(1), 1174-1179. <https://doi.org/10.21275/ART20203995>
- Chellamuthu, S., y Sekaran, E. C. [2019]. Fault detection in electrical equipment's images by using optimal features with deep learning classifier. *Multimedia Tools and Applications*, 78(19), 27333-27350. <https://doi.org/10.1007/s11042-019-07847-z>
- Chen, D., Liu, Y., Zhang, W., Zheng, M., y Zhang, S. [2018]. Detection of IGBT degradation in NPC inverter based on infrared thermography. *Journal of Computational Methods in Sciences and Engineering*, 18(2), 459-468. <https://doi.org/10.3233/JCM-180801>
- Choudhary, A., Goyal, D., y Letha, S. S. [2021]. Infrared Thermography-Based Fault Diagnosis of Induction Motor Bearings Using Machine Learning. *IEEE Sensors Journal*, 21(2), 1727-1734. <https://doi.org/10.1109/JSEN.2020.3015868>
- Duan, L., Yao, M., Wang, J., Bai, T., y Zhang, L. [2016]. Segmented infrared image analysis for rotating machinery fault diagnosis. *Infrared Physics and Technology*, 77, 267-276. <https://doi.org/10.1016/j.infrared.2016.06.011>
- Dutta, T., Santra, D., Peng-Lim, C., Sil, J., y Chottopadhyay, P. [2019]. Statistical Feature Analysis of Thermal Images from Electrical Equipment. *Springer Singapore*. <https://doi.org/10.1007/978-981-13-0860-4>
- Dutta, T., Sil, J., y Chottopadhyay, P. [2016]. Condition Monitoring of Electrical Equipment using Thermal

- Image Processing. *IEEE First International Conference on Control, Measurement and Instrumentation (CMI)*, Cmi, 311-315. <https://doi.org/10.1109/CMI.2016.7413761>
- Dziarki, K., Hulewicz, A., y Krawiecki, Z. (2019). Selection of the size of field of view in thermal imaging observations of small areas. *ITM Web of Conferences*, 28, 01040. <https://doi.org/10.1051/itmconf/20192801040>
- FLIR Systems Inc. (2016). Temperature guns versus thermal imaging thecnology. *FLIR Systems Inc.* <https://www.flir.com/discover/rd-science/temperature-guns-versus-thermal-imaging-technology/>
- FLIR Systems Inc. (2018a). 7 Things to Know When Selecting an IR Camera; for research and development. *En FLIR Systems Inc.* <https://www.flir.com/discover/rd-science/7-things-to-know-when-selecting-an-ir-camera-for-research--development>
- FLIR Systems Inc. (2018b). How far can you go? *En FLIR Systems Inc.* (Vol. 1). <https://doi.org/https://doi.org/10.1108/eum000000004457>
- Gallardo-saavedra, S., Hernández-callejo, L., Duque-pérez, Ó., Gallardo, S., y Hernández, L. (2019). Analysis and characterization of PV module defects by thermographic inspection. *Revista Facultad de Ingeniería Universidad de Antioquia*, 93, 92-104. <https://doi.org/10.17533/udea.redin.20190517>
- Glowacz, A., Glowacz, A., y Glowacz, Z. (2017). Detection of short-circuits of dc motor using thermographic images, binarization and K-NN classifier. *Tehnicki vjesnik - Technical Gazette*, 24(4), 1013-1018. <https://doi.org/10.17559/tv-20150924194102>
- Glowacz, A., y Glowacz, Z. (2016). Diagnostics of stator faults of the single-phase induction motor using thermal images, MoASoS and selected classifiers. *Measurement: Journal of the International Measurement Confederation*, 93, 86-93. <https://doi.org/10.1016/j.measurement.2016.07.008>
- Glowacz, A., y Glowacz, Z. (2017). Infrared Physics & Technology Diagnosis of the three-phase induction motor using thermal imaging. *Infrared Physics and Technology*, 81, 7-16. <https://doi.org/10.1016/j.infrared.2016.12.003>
- Gonzalez, R., y Woods, R. (2008). *Digital image processing, 2nd ed.* (Vol. 69, Número 9, pp. 1174-1175). <https://doi.org/10.1109/proc.1981.12153>
- Gyorok, G., y Beszedes, B. (2019). Using thermal imaging cameras to test electronical systems. *CANDO-EPE 2018 - Proceedings IEEE International Conference and Workshop in Obuda on Electrical and Power Engineering*, 147-151. <https://doi.org/10.1109/CANDO-EPE.2018.8601159>
- Haider, M., Doegar, A., y Verma, R. K. (2018). Fault Identification in Electrical Equipment using Thermal Image Processing. *2018 International Conference on Computing, Power and Communication Technologies (GUCON)*, 853-858. <https://doi.org/10.1109/GUCON.2018.8675108>
- Huda, A. S.N., y Taib, S. (2013). Suitable features selection for monitoring thermal condition of electrical equipment using infrared thermography. *Infrared Physics and Technology*, 61, 184-191. <https://doi.org/10.1016/j.infrared.2013.04.012>
- Huda, A S Nazmul, y Taib, S. (2013). Application of infrared thermography for predictive / preventive maintenance of thermal defect in electrical equipment. *Applied Thermal Engineering*, 61(2), 220-227. <https://doi.org/10.1016/j.applthermaleng.2013.07.028>
- Hui, Z., y Fuzhen, H. (2015). An intelligent fault diagnosis method for electrical equipment using infrared images. *Proceedings of the 34th Chinese Control Conference, 2015*, 6372-6376. <https://doi.org/10.1109/ChiCC.2015.7260642>
- Jadin, M. S., Taib, S., y Ghazali, K. H. (2014). Feature extraction and classification for detecting the thermal faults in electrical installations. *Measurement*, 57, 15-24. <https://doi.org/10.1016/j.measurement.2014.07.010>
- Jadin, M. S., Taib, S., y Ghazali, K. H. (2015). Finding region of interest in the infrared image of electrical installation. *Infrared Physics and Technology*, 71, 329-338. <https://doi.org/10.1016/j.infrared.2015.05.010>
- Khamisan, N., Ghazali, K. H., y Zin, A. H. M. (2015). A thermograph image extraction based on color

- features for induction motor bearing fault diagnosis monitoring. *ARNP Journal of Engineering and Applied Sciences*, 10(22), 17095-17101.
- Kim, J. S., Choi, K. N., y Kang, S. W. [2021]. Infrared thermal image-based sustainable fault detection for electrical facilities. *Sustainability (Switzerland)*, 13(2), 1-16. <https://doi.org/10.3390/su13020557>
- Kimande, J., Mwangi, E., y Gatari, M. [2021]. Application of Infrared Thermography in Fault Detection and Preventive Maintenance in Three-Phase Distribution Transformers. *International Journal of Computer Applications*, 174(12), 7-12. <https://doi.org/10.5120/ijca2021920995>
- Kostic, N., Hadziefendic, N., Tasic, D., y Kostic, M. [2021]. Improved measurement accuracy of industrial-commercial thermal imagers when inspecting low-voltage electrical installations. *Measurement*, 185, 109934. <https://doi.org/https://doi.org/10.1016/j.measurement.2021.109934>
- Kumar, S., Jena, P., Sinha, A., y Gupta, R. [2017]. Application of infrared thermography for non-destructive inspection of solar photovoltaic module. *Journal of Non-Destructive Testing*, 15(9), 25-32.
- Kurukuru, V. S. B., y Khan, M. A. [2019]. Fault classification for Photovoltaic Modules Using Thermography and Machine Learning Techniques. *2019 International Conference on Computer and Information Sciences (ICCIS)*, 1-6.
- Kurukuru, V. S., Haque, A., y Khan, M. A. [2019]. Fault Classification for Photovoltaic modules using Thermography and Image Processing. *2019 IEEE Industry Applications Society Annual Meeting, IAS 2019*, 1-6. <https://doi.org/10.1109/IAS.2019.8912356>
- Laxmi, M. R. [2021]. Thermal Imaging-Based Fault Diagnosis of Electronics Circuit Boards. En R. C. Bansal, A. Agarwal, y V. K. Jadoun (Eds.), *Advances in Energy Technology (pp. 111-121)*. Springer Singapore.
- Liu, H., Bao, C., Xie, T., Gao, S., Song, X., y Wang, W. [2019]. Research on the intelligent diagnosis method of the server based on thermal image technology. *Infrared Physics and Technology*, 96, 390-396. <https://doi.org/10.1016/j.infrared.2018.08.028>
- Liu, X. Q., y Jiang, J. G. [2013]. Study of circuits fault detection based on infrared technology. *Applied Mechanics and Materials*, 385-386, 618-621. <https://doi.org/10.4028/www.scientific.net/AMM.385-386.618>
- Lo, N. G., Flaus, J. M., y Adrot, O. [2019]. Review of Machine Learning Approaches in Fault Diagnosis applied to IoT Systems. *2019 International Conference on Control, Automation and Diagnosis, ICCAD 2019 - Proceedings*. <https://doi.org/10.1109/ICCAD46983.2019.9037949>
- Lopez-Perez, D., y Antonino-Daviu, J. [2017]. Application of Infrared Thermography to Failure Detection in Industrial Induction Motors: Case Stories. *IEEE Transactions on Industry Applications*, 53 (3), 1901-1908. <https://doi.org/10.1109/TIA.2017.2655008>
- Maciel, G., Aquino, R., y Lira, M. [2017]. Thermography and artificial intelligence in transformer fault detection. *Electrical Engineering*. <https://doi.org/10.1007/s00202-017-0595-2>
- Mahfurdz, A., Saher, R., Ghani, W., y Pi, W. [2020]. Electronic circuit failure detection using thermal image. *Open Access Library Journal*, 7, 1-7. <https://doi.org/10.4236/oalib.1106662>
- Mamchur, Y., Ivanova, V., Monastyrsky, G., Melnychenko, T., Zheng, G., y Voronov, S. [2020]. Thermography investigation of soldered joints for LED mounting. *2020 IEEE 40th International Conference on Electronics and Nanotechnology, ELNANO 2020 - Proceedings*, 143-147. <https://doi.org/10.1109/ELNANO50318.2020.9088886>
- Mehta, A., Goyal, D., Choudhary, A., Pabla, B. S., y Belghith, S. [2021]. Machine Learning-Based Fault Diagnosis of Self-Aligning Bearings for Rotating Machinery Using Infrared Thermography. *Mathematical Problems in Engineering*, 2021. <https://doi.org/10.1155/2021/9947300>
- Muralidhar, C., y Reddy, M. V. [2014]. Infrared thermography: A versatile tool. *Asia Pacific Conference on Non-Destructive Testing*, 14, 1-6. <https://www.ndt.net/article/apcndt2013/papers/121.pdf>
- Research and*, V5(04), 685-687. <https://doi.org/10.17577/ijertv5is041051>
- Ng, S. C. [2017]. Principal component analysis to reduce

- dimension on digital image. *Procedia Computer Science*, 111, 113-119. <https://doi.org/10.1016/j.procs.2017.06.017>
- Niazi, K. A. K., Akhtar, W., Khan, H. A., Yang, Y., y Athar, S. (2019). Hotspot diagnosis for solar photovoltaic modules using a Naive Bayes classifier. *Solar Energy*, 190(February), 34-43. <https://doi.org/10.1016/j.solener.2019.07.063>
- Novizon, y Abdul-Malek, Z. (2016). First Order Statistical Features Thermal Images for Surge Arrester Fault Classification. *Applied Mechanics and Materials*, 818, 91-95. <https://doi.org/10.4028/www.scientific.net/amm.818.91>
- Nunak, T., Rakrueangdet, K., Nunak, N., y Suesut, T. (2015). Thermal image resolution on angular emissivity measurements using infrared thermography. *Lecture Notes in Engineering and Computer Science*, 1(March 2015), 323-327.
- Olivatti, Y., Penteado, C., Aquino, P. T., y Filev, R. (2018). Analysis of artificial intelligence techniques applied to thermographic inspection for automatic detection of electrical problems. *2018 IEEE International Smart Cities Conference (ISC2)*, 1-5.
- Osornio-Rios, A. R., Antonino-Daviu, J. A., y Romero-Troncoso, R. D. J. (2019). Recent industrial applications of infrared thermography: A review. *IEEE Transactions on Industrial Informatics*, 15, 615-625. <https://doi.org/10.1109/TII.2018.2884738>
- Pal, D., Meyur, R., Menon, S., Reddy, M. J. B., y Mohanta, D. K. (2018). Real-time condition monitoring of substation equipment using thermal cameras. *IET Generation, Transmission and Distribution*, 12 (4), 895-902. <https://doi.org/10.1049/iet-gtd.2017.0096>
- Palimkar, N., y Bhole, A. A. (2016). Fault prediction in electrical equipments using thermographic inspection. *International Journal of Engineering Research and Technology*, 5, 685-687. <https://doi.org/10.17577/ijertv5is041051>
- Paolanti, M., y Frontoni, E. (2020). Multidisciplinary Pattern Recognition applications: A review. *Computer Science Review*, 37, 100276. <https://doi.org/10.1016/j.cosrev.2020.100276>
- Pavel, S. M., Aiordachioaie, D., y Frangu, L. (2019). Automated Thermal Images Processing System for Change Detection and Diagnosis. *SIITME 2019 - 2019 IEEE 25th International Symposium for Design and Technology in Electronic Packaging, Proceedings*, October, 316-321. <https://doi.org/10.1109/SIITME47687.2019.8990719>
- Petrosyants, K. O., Kharitonov, I. A., Ryabov, N. I., Kozyanko, P. A., y Lvov, B. G. (2016). Hardware-software subsystem for multilevel thermal fault detection and analysis of electronic components. *2016 International Siberian Conference on Control and Communications, SIBCON 2016 - Proceedings*, 1-6. <https://doi.org/10.1109/SIBCON.2016.7491809>
- Playà-Montmany, N., y Tattersall, G. J. (2021). Spot size, distance and emissivity errors in field applications of infrared thermography. *Methods in Ecology and Evolution*, 12 (5), 828-840. <https://doi.org/https://doi.org/10.1111/2041-210X.13563>
- Rakrueangdet, K., Nunak, N., Suesut, T., y Sritham, E. (2016). Emissivity measurements of reflective materials using infrared thermography. *Lecture Notes in Engineering and Computer Science*, 1, 372-375.
- Rauber, T. W., da Silva Loca, A. L., de Assis Boldt, F., Rodrigues, A. L., y Varejão, F. M. (2021). An experimental methodology to evaluate machine learning methods for fault diagnosis based on vibration signals. *Expert Systems with Applications*, 167, 114022. <https://doi.org/https://doi.org/10.1016/j.eswa.2020.114022>
- Redon, P., Romero-Troncoso, R. J., Picazo-Rodenas, M. J., y Antonino-Daviu, J. (2017). Reliable methodology for online fault diagnosis in induction motors using passive infrared thermography. *Proceedings of the 2017 IEEE 11th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives, SDEMPED 2017, 2017-Janua*, 600-607. <https://doi.org/10.1109/DEMPED.2017.8062416>
- Resendiz-choa, E., Osornio-rios, R. A., Benitez-rangel, J. P., Romero-troncoso, R. D. E. J., Member, S., y Morales-hernandez, L. A. (2018). Induction Motor Failure Analysis : An Automatic Methodology Based on Infrared Imaging. *IEEE Access*, 6, 76993-77003.

- <https://doi.org/10.1109/ACCESS.2018.2883988>
Resendiz-Ochoa, E., Saucedo-Dorantes, J. J., Benitez-Rangel, J. P., Osornio-Rios, R. A., y Morales-Hernandez, L. A. [2020]. Novel methodology for condition monitoring of gear wear using supervised learning and infrared thermography. *Applied Sciences (Switzerland)*, 10(2), 1-18. <https://doi.org/10.3390/app10020506>
- Rhyne, T. M. [2017]. *Applying color theory to Digital Media and Visualization*. CRC Press. <https://doi.org/https://doi.org/10.1201/9781315380384>
- Salazar, A. M., y Macabebe, E. Q. B. [2016]. Hotspots Detection in Photovoltaic Modules Using Infrared Thermography. *MATEC Web of Conferences*, 70. <https://doi.org/10.1051/mateconf/20167010015>
- Sanati, H., Wood, D., y Sun, Q. [2018]. Condition monitoring of wind turbine blades using active and passive thermography. *Applied Sciences (Switzerland)*, 8(10). <https://doi.org/10.3390/app8102004>
- Sanchez-Londono, S. R. D. [2021]. Thermographic indicators for the state assessment of rolling bearings. *FAC-PapersOnLine*, 54, 1218-1223. <https://doi.org/https://doi.org/10.1016/j.ifacol.2021.08.208>
- Saravanan, R., y Sujatha, P. [2018]. Algorithms : A Perspective of Supervised Learning Approaches in Data Classification. *2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS)*, Iccics, 945-949.
- Sarawade, A. A., y Charniya, N. N. [2019]. Detection of Faulty Integrated Circuits in PCB With Thermal Image Processing. *2019 International Conference on Nascent Technologies in Engineering (ICNTE)*, Icn-te, 1-6. <https://doi.org/10.1109/ICNTE44896.2019.8946061>
- Schuss, C., Remes, K., Leppänen, K., Eichberger, B., y Fabritius, T. [2021]. Thermography of Photovoltaic Panels and Defect Detection Under Outdoor Environmental Conditions. *2021 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, 1-6. <https://doi.org/10.1109/I2MTC50364.2021.9460099>
- Sharma, P., y Kaur, M. [2013]. Classification in Pattern Recognition: A Review. *International Journal of Advanced Research in Computer Science and Software Engineering*, 3(4), 2277-128.
- Shereena, V.B., y David, J. M. [2015]. Comparative Study of Dimensionality Reduction Techniques Using PCA and LDA for Content Based Image Retrieval. *Computer Science & Information Technology*, 41-55. <https://doi.org/10.5121/csit.2015.50905>
- Stoynova, A., Bonev, B., y Brayanov, N. [2018]. Thermographic Approach for Reliability Estimation of PCB. *Proceedings of the International Spring Seminar on Electronics Technology, 2018-May*, 1-7. <https://doi.org/10.1109/ISSE.2018.8443675>
- Suguna, M., Mohamed, S., y Sanofer, I. [2016]. Fault Localisation Of Electrical Equipments Using Thermal Imaging Technique. *2016 International Conference On Emerging Technological Trends [ICETT]*, 1-3. <https://doi.org/10.1109/ICETT.2016.7873778>
- Sun, J., Wang, Z., Xie, C., Duan, C., y Li, T. [2019]. Application of Infrared Non-destructive Defect Location in Components. *2019 IEEE 3rd International Conference on Circuits, Systems and Devices, ICCSD 2019*, 177-181. <https://doi.org/10.1109/ICCSD.2019.8842947>
- Taheri-garavand, A., Ahmadi, H., Omid, M., Saeid, S., Mollazade, K., John, A., Smith, R., y Maria, G. [2015]. An intelligent approach for cooling radiator fault diagnosis based on infrared thermal image processing technique. *Applied Thermal Engineering*, 87, 434-443. <https://doi.org/10.1016/j.applthermaleng.2015.05.038>
- Tharwat, A., Gaber, T., Ibrahim, A., y Ella, A. [2017]. Linear discriminant analysis : A detailed tutorial. *AI Communications* 30, 30, 169-190. <https://doi.org/10.3233/AIC-170729>
- Ullah, I., Khan, R. U., Yang, F., y Wuttisittikulij, L. [2020]. Deep learning image-based defect detection in high voltage electrical equipment. *Energies*, 13(2). <https://doi.org/10.3390/en13020392>
- Ullah, I., Yang, F., Khan, R., Liu, L., Yang, H., Gao, B., y Sun, K. [2017]. Predictive maintenance of power substation equipment by infrared thermography using a machine-learning approach. *Energies*, 10(12). <https://doi.org/10.3390/en10121987>

- Umair, M., Farhaj, H., Masud, M., Dad, K., y Zafar, A. (2020). A machine learning framework to identify the hotspot in photovoltaic module using infrared thermography. *Solar Energy*, 208(July), 643-651. <https://doi.org/10.1016/j.solener.2020.08.027>
- Vollmer, M., y Möllmann, K.-P. (2018). *Infrared Thermal Imaging - Fundamentals, Research and Applications*. Wiley-VCH. <https://doi.org/10.1002/9783527693306>
- Wang, J., y Zhao, C. (2019). Broad Learning System Based Visual Fault Diagnosis for Electrical Equipment Thermography Images. *Proceedings 2018 Chinese Automation Congress*, 1632-1637. <https://doi.org/10.1109/CAC.2018.8623741>
- Wargulski, D. R., May, D., Petrick, J., Schacht, R., Wunderle, B., y Abo Ras, M. (2020). Pulsed Infrared Thermography Failure Analysis of Low-emissivity Specimens Without Contaminations Caused by High-emissivity Coatings. *2020 26th International Workshop on Thermal Investigations of ICs and Systems*, 1-5. <https://doi.org/10.1109/THERMINIC49743.2020.9420531>
- Wronkiewicz, A. (2016). Approach to automated hot spot detection using image processing for thermographic inspections of power transmission lines. *Diagnostyka*, 17 (2), 81-86.
- Yang, W., Zhang, X., y Ma, H. (2016). An inspection robot using infrared thermography for belt conveyor. *2016 13th International Conference on Ubiquitous Robots and Ambient Intelligence, URAI 2016*, 400-404. <https://doi.org/10.1109/URAI.2016.7734069>
- Zhang, Y., y Fjeld, M. (2020). Condition Monitoring for Confined Industrial Process Based on Infrared Images by Using Deep Neural Network and Variants. . *Association for Computing Machinery International Conference Proceeding Series*, 99-106. <https://doi.org/10.1145/3388818.3388823>

