

2022 DETECCIÓN DE FALLAS EN SERVIDORES UTILIZANDO DESCRIPTORES ESTADÍSTICOS EN IMÁGENES TERMOGRÁFICAS

Ing. Cinthia Nohemi Espinoza Del Angel



Universidad Autónoma de Querétaro
Facultad de Ingeniería

**DETECCIÓN DE FALLAS EN SERVIDORES UTILIZANDO
DESCRIPTORES ESTADÍSTICOS EN IMÁGENES
TERMOGRÁFICAS**

TESIS

Que como parte de los requisitos para obtener el grado de

Maestra en Ingeniería de Calidad y Productividad

Presenta:

Ing. Cinthia Nohemi Espinoza Del Angel

Dirigido por:

Dra. Aurora Femat Díaz

Santiago de Querétaro, Qro. Junio 2022



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Maestría en Ingeniería de Calidad y
Productividad

**DETECCIÓN DE FALLAS EN SERVIDORES UTILIZANDO DESCRIPTORES
ESTADÍSTICOS EN IMÁGENES TERMOGRÁFICAS**
TESIS

Que como parte de los requisitos para obtener el grado de
Maestra en Ingeniería de Calidad y Productividad

Presenta:

Ing. Cinthia Nohemi Espinoza Del Angel

Dirigido por:

Dra. Aurora Femat Díaz

Dra. Aurora Femat Díaz
Presidente

M.I. Javier García Pérez
Secretario

M.I. Genaro Spíndola Barrón
Vocal

M.I. Arturo Escoto García
Suplente

M.I. José Juan Rodríguez Trejo
Suplente

Centro Universitario, Querétaro, Qro.

Junio 2022

México.

Esta tesis está dedicada a mis padres, gracias por sus consejos, su apoyo incondicional, por haberme forjado como persona y por motivarme siempre a salir adelante.

A mi pareja Josue Saenz, por estar a mi lado en momentos alegres y difíciles, por siempre creer en mí y brindarme su apoyo, paciencia, comprensión, cariño y amor.

A mis hermanas Karla y Hannia, quienes siempre me apoyan y festejan mis logros.

A mi abuelito Rafael Espinosa, quien nos brindó su amor incondicional a mi padre y a nuestra familia, espero que se encuentre muy orgulloso de su nieta y que desde el cielo siga bendiciéndome.

Agradecimientos

Agradezco a la Universidad Autónoma de Querétaro por haberme aceptado y abrirme las puertas para poder continuar con mi educación y carrera profesional, así como al Consejo Nacional de Ciencia y Tecnología (CONACYT) por el apoyo económico brindado durante la realización de este proyecto de tesis.

Un agradecimiento especial a mi asesora de tesis la Dra. Aurora Femat Díaz por haberme dado la oportunidad de colaborar con ella y haberme guiado durante el desarrollo de este proyecto. Agradezco infinitamente que me haya brindado su conocimiento científico, apoyo y confianza durante mi estancia en la universidad.

Un sincero agradecimiento al M.I. Javier García Pérez, M.I. Arturo Escoto García, M.I. Genaro Spíndola Barrón y al M.I. José Juan Rodríguez Trejo, integrantes del sínodo, por sus valiosas aportaciones, comentarios y revisiones en la presente investigación.

A los profesores de la maestría quienes me brindaron sus conocimientos y apoyo para seguir adelante.

A mis compañeros de clase quienes me ofrecieron su amistad, conocimiento, consejos y apoyo durante la maestría.

Resumen

Introducción. Un sistema de detección basado en termografía infrarroja permite reconocer fallas en un dispositivo a partir de datos extraídos de una imagen. Procesar esta información sin seleccionar un espacio de color adecuado puede reducir la exactitud del clasificador. Este estudio presenta una metodología para comprender la importancia de la selección adecuada de un espacio de color al caracterizar las condiciones de funcionamiento de un servidor.

Métodos. Una base de datos se emplea en este estudio. Los espacios de color y la escala de grises se utilizan para extraer descriptores estadísticos de imágenes térmicas. La caracterización de las condiciones se realizó mediante el análisis de componentes principales (ACP). La evaluación del modelo predictivo se hizo a partir del kNN y la matriz de confusión. El ANOVA a un nivel de confianza del 95 % se usa para determinar diferencias significativas entre los espacios utilizados. La prueba de Tukey establece los espacios de color con diferencia entre las medias de exactitud. Por último, el ACP se compara con la regresión LASSO.

Resultados. El espacio de color HSI caracteriza mejor las fallas analizadas con una precisión media del 73.17 %. Seguido del espacio HSV con una precisión del 72.56 %. Los espacios RGB y CMY tuvieron una precisión similar de 68.03 % y 68.29 %. Los peores rendimientos se obtuvieron con la escala de grises y el espacio CIE L*a*b, con un 64.36 % y 59.44 %, respectivamente. Los resultados de exactitud para los modelos de regresión LASSO fueron superiores al PCA. El promedio de exactitud del LASSO en escala de grises fue de 65.87 %; RGB, 74.64 %; CMY, 73.83 %; HSV, 76.67 %; HSI, 77.38 %; y CIE L*a*b, 66.49 %.

Conclusiones. Este estudio demostró que los espacios de color pueden influir en el modelo de predicción de la condición de un dispositivo. Cuando se trabaja con imágenes donde el color tiene un papel fundamental, como en las imágenes termográficas, la selección adecuada de un espacio de color se vuelve relevante, ya que estos pueden aumentar considerablemente la exactitud de un algoritmo de clasificación.

Palabras clave. *ACP, descriptores estadísticos, escala de grises, espacios de color, imagen térmica.*

Abstract

Introduction. A detection system based on infrared thermography makes it possible to recognize faults in a device from data extracted from an image. Processing this information without selecting an appropriate color space can reduce the accuracy of the classifier. This study presents a methodology to understand the importance of proper selection of a color space to characterize the operating conditions of a server.

Methods. A database is employed in this study. Color spaces and grayscale are used to extract statistical descriptors from thermal images. The characterization of conditions was performed by principal component analysis (PCA). Evaluation of the predictive model was done from the kNN and confusion matrix. ANOVA at the confidence level of 95 % is used to determine significant differences between the spaces used. Tukey's test establishes the color spaces with difference between the accuracy means. Finally, the PCA is compared with the LASSO regression.

Results. The HSI color space best characterizes the analyzed faults with an average accuracy of 73.17 %. Followed by HSV space with an accuracy of 72.56 %. The RGB and CMY spaces had a similar accuracy of 68.03 % and 68.29 %. The worst performances were obtained with grayscale and CIE L*a*b space with 64.36 % and 59.44 %, respectively. Accuracy results for LASSO regression models were superior to PCA. The average accuracy of LASSO in grayscale was 65.87 %; RGB, 74.64 %; CMY, 73.83 %; HSV, 76.67 %; HSI, 77.38 %; and CIE L*a*b, 66.49 %.

Conclusions. This study showed that color spaces can influence in a device condition prediction model. When working with images where color plays a key role, such as in thermographic images, the proper selection of a color space becomes relevant, as these can considerably increase the accuracy of a classification algorithm.

Keywords. *PCA, statistical descriptors, grayscale, color spaces, thermal imaging.*

Índice general

Agradecimientos	i
Resumen	iii
Abstract	v
Índice general	vi
Índice de figuras	ix
Índice de cuadros	x
Abreviaturas y siglas	xi
I Introducción	1
1.1 Justificación	3
1.2 Descripción del problema	5
II Revisión de la literatura	7
2.1 Antecedentes	7
2.2 Marco teórico	11
2.2.1 Servidor informático	11
2.2.2 Fallas en servidores	12
2.2.3 Sistemas de detección de fallas	13
2.2.4 Termografía infrarroja	14
2.2.5 Imagen digital	14
2.2.6 Imagen térmica	15
2.2.7 Tipos de termografía infrarroja	16
2.2.8 Aplicaciones de la TI pasiva en la industria	17

2.2.9	Metodología para la detección de fallas mediante TI pasiva	18
2.2.9.1	Adquisición de imágenes	19
2.2.9.2	Procesamiento de imágenes	21
2.2.9.2.1	Segmentación de la región de interés	21
2.2.9.2.2	Espacios de color	22
2.2.9.2.3	Escala de grises	24
2.2.9.2.4	Conversión RGB a otros espacios de color o es- cala de grises	25
2.2.9.3	Extracción de características	28
2.2.9.4	Selección de variables	29
2.2.9.4.1	Análisis de regresión	30
2.2.9.4.2	Regresión logística	31
2.2.9.4.3	Regresión logística penalizada	32
2.2.9.4.4	Análisis de componentes principales	33
2.2.9.5	Clasificación	34
2.2.9.5.1	Clasificación estadística	35
2.2.9.5.1.1	K-vecinos más cercanos	35
2.2.10	Métricas de desempeño para clasificadores	36
2.2.11	Métodos estadísticos de comparación múltiple	38
2.2.11.1	Análisis de varianza de una vía	38
2.2.11.2	Prueba de Tukey	40
III	Hipótesis	42
IV	Objetivos	43
4.1	Objetivo general	43
4.2	Objetivos específicos	43
V	Metodología	44
5.1	Base de datos de imágenes térmicas	44

5.2	Segmentación de la región de interés	46
5.3	Extracción de características	46
5.4	Caracterización de las condiciones	47
5.5	Clasificación de fallas	47
5.6	Evaluación de la metodología	48
5.7	Comparación de métodos de selección de variables	48
VI	Resultados y discusión	49
VII	Conclusión	67
	Referencias	82
Anexo A	Información de base de datos	84
Anexo B	Código para segmentación	85
Anexo C	Código para extracción de características	87
Anexo D	Algoritmo de ACP	88
Anexo E	Algoritmo de clasificación kNN	89
Anexo F	Resultados del ACP	90
Anexo G	Resultados VIF	91

Índice de figuras

Figura 2.1	Arquitectura cliente-servidor.	12
Figura 2.2	Diagrama de flujo de un sistema de detección de fallas.	13
Figura 2.3	Imagen térmica con vista a los datos de temperatura internos.	15
Figura 2.4	Esquema para el monitoreo de condición basado en TI pasiva.	16
Figura 2.5	Esquema para la detección de degradación de un material basado en TI activa.	17
Figura 2.6	Metodología para la detección de fallas mediante TI.	18
Figura 2.7	Campo de visión instantáneo (IFoV).	20
Figura 2.8	Ejemplo de imagen térmica segmentada.	21
Figura 2.9	Sistema cartesiano tridimensional de los espacios de color RGB y CMY.	22
Figura 2.10	Representación tridimensional de modelos de color HSI y HSV.	23
Figura 2.11	Representación del espacio de color CIE L*a*b.	24
Figura 2.12	Representación de la escala de grises.	25
Figura 2.13	Modelo de la matriz de confusión.	38
Figura 5.1	Diagrama de flujo de la metodología.	45
Figura 5.2	Imágenes muestra de la base de datos.	46
Figura 6.1	Segmentación del punto caliente en el servidor.	49
Figura 6.2	Gráfica PCA para los componentes 1 y 2.	52
Figura 6.3	Resultados de la comparación estadística del PCA+k-NN	57
Figura 6.4	Resultados de la comparación estadística	65
Figura 6.5	Precisión del modelo PCA vs LASSO.	66

Índice de cuadros

Cuadro 2.1	Aplicaciones de la termografía.	10
Cuadro 6.1	División de canales de los sistemas de color.	50
Cuadro 6.2	Matriz de datos RGB.	51
Cuadro 6.3	Resultados de KMO y prueba de Bartlett para el análisis de ACP.	51
Cuadro 6.4	Resultados de exactitud de los espacios de color para el método PCA+k- NN.	55
Cuadro 6.5	Resultados de las pruebas Shapiro-Wilks y Bartlett para la verificación de supuestos del ANOVA para el método PCA+k-NN.	56
Cuadro 6.6	Resultados del ANOVA en PCA+k-NN.	56
Cuadro 6.7	Resultado LASSO para las representaciones de color	58
Cuadro 6.8	Resultados de exactitud de los espacios de color para el método LASSO+k- NN.	64
Cuadro 6.9	Resultados de las pruebas Shapiro-Wilks y Bartlett para la verificación de supuestos del ANOVA para el método LASSO+k-NN.	65
Cuadro 6.10	Resultados del ANOVA en LASSO+k-NN.	65

Abreviaturas y siglas

ACP	Análisis de Componentes Principales.
ANFIS	de las siglas en inglés Adaptive Neuro-Fuzzy Inference System, es decir, sistema de inferencia adaptable neuro difuso.
ANOVA	de las siglas en inglés Analysis of variance, es decir, análisis de varianza.
CIE L*a*b	de las siglas en inglés International Commission on Illumination L*a*b, es decir, Comisión Internacional de Iluminación L*a*b.
CMY	de las siglas en inglés Cian, Magenta and Yellow, es decir, cian, magenta y amarillo.
CONACYT	Consejo Nacional de Ciencia y Tecnología.
CP	Componente Principal.
CPU	de las siglas en inglés Central Processing Unit, es decir, unidad central de procesamiento.
FoV	de las siglas en inglés Field of View, es decir, campo de visión.
HSI	de las siglas en inglés Hue, Saturation and Intensity, es decir, tono, saturación e intensidad.
HSV	de las siglas en inglés Hue, Saturation and Value, es decir, tono, saturación y valor.
IFoV	de las siglas en inglés Instantaneous Field Of View, es decir, campo de visión instantáneo.
k-NN	de las siglas en inglés k-Nearest Neighbors, es decir, k-vecinos más cercanos.
LASSO	de las siglas en inglés Least Absolute Shrinkage and Selection Operator, es decir, selección de operadores y contracción del menor absoluto.
MLP	de las siglas en inglés Multilayer Perceptron, es decir, perceptrón multicapa.

MSE	de las siglas en inglés Mean Squared Error, es decir, error cuadrático medio.
NB	de las siglas en inglés Naive Bayes, es decir, bayes ingenuos.
OvR	de las siglas en inglés One-vs-Rest, es decir, uno-vs-todos.
PCA	de las siglas en inglés Principal Component Analysis, es decir, Análisis de Componentes Principales.
PCB	de las siglas en inglés Printed Circuit Board, es decir, placa de circuito impreso.
RGB	de las siglas en inglés Red, Green and Blue, es decir, rojo, verde y azul.
ROI	de las siglas en inglés Region of Interest, es decir, región de interés.
SVM	de las siglas en inglés Support-Vector Machines, es decir, máquinas de vectores de soporte.
TI	Termografía Infrarroja.
USD	de las siglas en inglés United States dollar, es decir, dólar de los Estados Unidos.
VIF	de las siglas en inglés Variance Inflation Factor, es decir, factor de inflación de la varianza.

I. Introducción

En la actualidad, la creciente demanda de aplicaciones de la información (comercio electrónico, Big Data), la computación en la nube y otros servicios de internet, han ocasionado el incremento del uso de los centros de datos. Estos son instalaciones físicas centralizadas donde se alojan, sistemas de almacenamiento, controladores de aplicaciones, servidores, etc. (Liu *et al.*, 2019,1). Su constante aumento exige que los servidores de datos evolucionen constantemente hacia una alta densidad de potencia y compactación de componentes (Liu *et al.*, 2019). Desafortunadamente, estas características provocan un mayor consumo energía, generando un flujo excesivo de calor. Este problema se ha convertido en la razón principal del tiempo de inactividad del servidor, causando daños en los componentes del hardware como, la CPU, la fuente de alimentación, la tarjeta madre, el ventilador, entre otros (Lee *et al.*, 2018a; Pertet y Narasimhan, 2005; Sankar *et al.*, 2013). Estos tipos de falla pueden ocasionar tiempos de inactividad y pérdidas económicas (Bagavathiappan *et al.*, 2013; Choudhary *et al.*, 2021; Singh *et al.*, 2016). Por lo tanto, es importante ubicar con precisión el origen del sobrecalentamiento y realizar un diagnóstico inteligente de la causa.

Algunas investigaciones en centros de datos han realizado el perfilado térmico de los servidores utilizando termómetros tradicionales y cámaras térmicas (Liu *et al.*, 2013; Mansley *et al.*, 2011). Sin embargo, un termómetro tradicional mide la temperatura en un solo punto; por lo que, la exactitud es demasiado baja para analizar con éxito los puntos críticos. El uso de imágenes infrarrojas puede remediar estos inconvenientes (Wysobunri *et al.*, 2020). La termografía infrarroja (TI) es un método de inspección sin contacto, que se ha ido incorporando en centros de datos para el análisis y monitoreo en tiempo real del estado de un servidor (Lee *et al.*, 2018a). Se basa en el análisis de la información contenida en una imagen térmica. Esta información es extraída mediante técnicas de procesamiento de imágenes utilizando operaciones matemáticas como, geometría, álgebra lineal, aritmética, lógica binaria, ecuaciones diferenciales, probabilidad, estadística, etc.

El procesamiento de imágenes se ha utilizado en algoritmos de aprendizaje automático para diferenciar entre un servidor en buen estado y uno defectuoso (Aujeszky *et al.*, 2017; Umair *et al.*, 2020). Estos sistemas de detección asignan una clase de falla dependiendo de las características de la imagen analizada. Desafortunadamente, existen desafíos en la detección automática. Su exactitud se puede ver afectada por factores internos y externos involucrados en la adquisición de la imagen, la segmentación, la selección y extracción de características (Marinetti y Cesaratto, 2012; Playà-Montmany y Tattersall, 2021; Rakrueangdet *et al.*, 2016).

Para analizar una falla mediante el aprendizaje automático, comúnmente el termograma es adquirido en formato RGB, por lo que dependiendo de la necesidad y la aplicación se realiza su conversión a diferentes espacios de color (Espinoza-del Angel y Femat-Díaz, 2021). Los más usados en el desarrollo de sistemas de detección de fallas son rojo, verde y azul (RGB, por sus siglas en inglés); matiz, saturación e intensidad (HSI, por sus siglas en inglés); tono, saturación y valor (HSV, por sus siglas en inglés); cian, magenta y amarillo (CMY, por sus siglas en inglés); Comisión Internacional de Iluminación L^*a^*b (CIE L^*a^*b , por sus siglas en inglés); y escala de grises (Chellamuthu y Sekaran, 2019; Haider *et al.*, 2018; Khamisan *et al.*, 2015).

El HSI, HSV y CIE L^*a^*b son considerados los más precisos para extraer las características de la imagen térmica (Al-Musawi *et al.*, 2020; Haider *et al.*, 2018; Salazar y Macabebe, 2016). Mientras que el CMY y la escala de grises son los que presentan la mayor pérdida de información (Akole y Kulkarni, 2016; Kurukuru *et al.*, 2019a; Resendiz-Ochoa *et al.*, 2018). Se cree que el RGB es el ideal puesto que no hay necesidad de llevar a cabo una conversión (Akole y Kulkarni, 2016; Chellamuthu y Sekaran, 2019; Khamisan *et al.*, 2015). El espacio de color especifica cómo se representa la información de color en una imagen y esta puede perderse o modificarse en el proceso de conversión. En este sentido, los espacios de color podrían influir en la exactitud de un sistema de detección que emplea termogramas

(Akole y Kulkarni, 2016; Chellamuthu y Sekaran, 2019; Khamisan *et al.*, 2015).

La ubicación precisa del sobrecalentamiento y el diagnóstico inteligente de la causa de falla es uno de los temas más relevantes para los centros de datos. Los servidores informáticos funcionan continuamente, por esta razón siempre presentan un riesgo de falla. Estos son el corazón de la comunicación hoy en día. Diversas aplicaciones médicas, militares, entidades financieras, comercio electrónico o transporte dependen del correcto funcionamiento de estos (Shahzad *et al.*, 2019; Wang *et al.*, 2012). Por lo anteriormente expuesto, es importante estudiar el efecto de la representación del color de la imagen térmica sobre la toma de decisiones de un sistema de detección de fallas; con la finalidad de contribuir a la creación de sistemas de clasificación más exactos y precisos.

Este documento presenta una metodología para comparar la eficiencia de las conversiones a distintos modelos de color y escala de grises como una herramienta para elegir el que mejor representa las condiciones de falla de un servidor. La tesis se encuentra dividida en siete capítulos, en donde se expone el planteamiento del problema, la hipótesis y los objetivos. También se desarrolla la revisión de la literatura que contiene las bases teóricas del proyecto. En la metodología se describen los procedimientos que se realizaron para cumplir con el objetivo de este estudio. Por último, se presentan los resultados y conclusiones.

1.1. Justificación

Los métodos tradicionales de detección manual pocas veces cumplen con los requerimientos actuales de localización de fallas. En los últimos años, varios investigadores se han centrado en la TI para el monitoreo de condición y el diagnóstico de fallas, permitiendo la detección oportuna de problemas y defectos (Dong y Chen, 2019; Khamisan *et al.*, 2015).

Esta herramienta se ha implementado en estudios de diseño y monitoreo de la distribución térmica de dispositivos mecánicos, eléctricos y electrónicos (Osornio-Rios *et al.*, 2019). Estos equipos se ven muy afectados por sus propiedades térmicas, por lo cual la amenaza de sobrecalentamiento es una preocupación importante para la industria (Hu *et al.*, 2012; Song *et al.*, 2014). Por este motivo, los sistemas de detección de fallas mediante imágenes térmicas requieren de un modelo predictivo de clasificación más exacto y preciso, que dé como resultado una mejor toma de decisiones. Diversas investigaciones se enfocan en solucionar problemas relacionados con la adquisición de la imagen, métodos de segmentación; y selección de características. (Al-Musawi *et al.*, 2020; Duarte *et al.*, 2014; Jia *et al.*, 2019; Khamisan *et al.*, 2015; Shereena y David, 2015). Generalmente, estos dos últimos suelen ser los pasos más relevantes para una medición automática (Ghojogh *et al.*, 2019).

En estos procesos el modelo de color usado es de gran importancia porque define y resalta características particulares para la detección de diversos tipos de falla. En la extracción de características, se han obtenido propiedades estadísticas y de color de varios espacios como, por ejemplo, RGB, CMY, HSV, HSI y CIE L*a*b; y escala de grises. De estos, el espacio RGB y la escala de grises son los más utilizados, pero el uso de estas representaciones no se ha justificado (Aghaei *et al.*, 2015; Akole y Kulkarni, 2016; Chen *et al.*, 2018; Gallardo-saavedra *et al.*, 2019; Hui y Fuzhen, 2015; Khamisan *et al.*, 2015; Olivatti *et al.*, 2018; Resendiz-Ochoa *et al.*, 2018).

Aunque las características de color extraídas de una imagen son una fuente importante de información, aún no se han realizado estudios para comprar la exactitud que otorgan los datos obtenidos de los espacios de color al clasificar fallas a partir de imágenes. En este trabajo se propone utilizar un análisis de componentes principales, empleando descriptores estadísticos como entrada para definir un modelo predictivo de clasificación a partir de características provenientes de diversos espacios de color; y definir el que mejor representa el contenido de la región de interés (ROI, por sus siglas en inglés). La finalidad de este estudio es proponer una herramienta para metodologías que empleen aprendizaje automático y

procesamiento de imágenes. En proyecto de investigación se aplica a la identificación de fallas en servidores utilizando termogramas. La metodología presentada también fue aplicada para demostrar que la selección adecuada de un espacio de color proporcionan una mejor caracterización en dos tipos de cáncer, la leucemia linfocítica aguda y el mieloma múltiple (Espinoza-Del Angel y Femat-Díaz, 2022).

1.2. Descripción del problema

De las imágenes térmicas se pueden extraer características que sirven para describir diversos tipos de fallas o condiciones de un elemento. Tradicionalmente, la extracción de variables se determina manualmente por un usuario y este decide desde su perspectiva las características útiles (García *et al.*, 2015). Obtener la máxima información disponible suele ser considerado lo más razonable para lograr mejores resultados en la clasificación. Sin embargo, en el aprendizaje automático una gran cantidad de datos provoca que el error de clasificación aumente (Chen *et al.*, 2020; Khalid *et al.*, 2014).

Por este motivo, para la integración de una metodología capaz de detectar fallas en servidores es importante el uso de técnicas de reducción de dimensionalidad (Cai *et al.*, 2018; García *et al.*, 2015). Estas proyectan un nuevo conjunto de variables con menor dimensión, las cuales suelen ser combinaciones ortogonales del conjunto de datos original. A partir de ellas se detectan las variables relevantes y se eliminan los datos redundantes (Janecek *et al.*, 2008; Xue *et al.*, 2016). Este proceso acelera los algoritmos de minería de datos y mejora la precisión predictiva (Khalid *et al.*, 2014). El enfoque de extracción de características más popular y ampliamente utilizado es el análisis de componentes principales (Ma y Yuan, 2019; Sun *et al.*, 2019b).

Existen aspectos que hay que considerar al aplicar este análisis en el aprendizaje supervisado. Parte del proceso implica verificar y asegurarse de que estos realmente puedan analizarse con esta técnica. Para esto, los supuestos estadísticos a tener en cuenta son, la

adecuación de muestreo, la correlación entre variables y la no existencia de valores atípicos (Abdi y Williams, 2010).

Un paso previo al procesamiento del ACP es la estandarización de los datos, si no se realiza las entidades con rangos de números más grandes tendrán covarianzas más altas (Salem y Hussein, 2019). Finalmente, lo más importante es la baja interpretabilidad de los componentes principales. Estos son combinaciones lineales de las características de los datos originales, pero no son de fácil interpretación. Es difícil conocer las características más relevantes del conjunto de datos después de calcular los componentes principales (CP), por lo que es importante tener especial cuidado en su análisis e interpretación (Prieto-Moreno *et al.*, 2015).

II . Revisión de la literatura

2.1. Antecedentes

Los centros de procesamiento de datos siguen creciendo a un ritmo sin precedentes. Según el instituto de investigación Arizton, el mercado mexicano de centros de datos alcanzará \$905 millones USD en inversiones para 2026 y registrará una tasa de crecimiento anual compuesta de 8.33 % durante el período 2021-2026 (Arizton, 2021). Esto generará una gran demanda de servidores de alta densidad con circuitos electrónicos compactos (Delloite, 2019). Sin embargo, un alto rendimiento provoca el aumento del estrés térmico generando fallas de refrigeración o hardware (Liu *et al.*, 2017a; Sankar *et al.*, 2013).

Detectar las anomalías térmicas de estos elementos es una tarea desafiante. Muchos de los sistemas tradicionales de detección de fallas, realizan procedimientos con pruebas físicas con las que no es posible realizar una detección temprana de los problemas relacionados con la gestión de la temperatura (Alaoui *et al.*, 2019; Sankar *et al.*, 2013; Shahzad *et al.*, 2019; Stoynova *et al.*, 2018). Como consecuencia se reduce el tiempo de vida del servidor u ocurren tiempos de inactividad no planificados. Por este motivo, los centros de datos motivan el desarrollo de sistemas de detección de fallas que efectúen diagnósticos precisos con la finalidad de alcanzar un mejor desempeño.

En la industria, el uso de sistemas de monitorización basados en termografía infrarroja ha ido en aumento. A diferencia de otros, permite observar la distribución de temperatura de los componentes del servidor y detectar problemas internos y externos para evitar daños (Al-Musawi *et al.*, 2020; Chellamuthu y Sekaran, 2019; Janssens *et al.*, 2015; Kurukuru *et al.*, 2019a; Wronkiewicz, 2016).

Esta técnica puede ser utilizada mediante una cámara termográfica, donde a través de imágenes llamadas termogramas, obtiene el mapa térmico de un objeto. Esta codifica de manera cuantitativa los valores de radiación infrarroja y provee una medición proporcional a la temperatura del objeto medido (Kurukuru *et al.*, 2019a; Salazar y Macabebe, 2016). La TI aplicada a sistemas de detección de fallas se clasifica en activa y pasiva. En la activa interviene una fuente de calor como excitación en el objeto de estudiado (Aghaei *et al.*, 2015; Salazar y Macabebe, 2016). En la pasiva, no se usa ninguna estimulación de calentamiento externo para provocar un flujo de calor (Alajmi *et al.*, 2019; Olivatti *et al.*, 2018).

La mayoría de los sistemas de detección y monitoreo de condición de fallas mediante TI se basan en la extracción de características de la imagen a través del procesamiento de imágenes. Para esto, es necesario seleccionar un espacio de color, el cual representa y describe las características que contiene una imagen para una condición de falla específica. Se han utilizado diferentes espacios como RGB (Khamisan *et al.*, 2015), HSV (Alajmi *et al.*, 2019; Haider *et al.*, 2018), CMY (Glowacz y Glowacz, 2017; Glowacz *et al.*, 2017), CIE L * a * b (Salazar y Macabebe, 2016), HSI (Suguna *et al.*, 2016) y la escala de grises (EG) (Aghaei *et al.*, 2015; Janssens *et al.*, 2015; Kim *et al.*, 2015).

De acuerdo con algunos autores, el espacio de color RGB es el ideal para extraer características de una imagen térmica (Akole y Kulkarni, 2016; Chellamuthu y Sekaran, 2019; Khamisan *et al.*, 2015). Otros autores justifican el uso de la escala de grises para facilitar el manejo de las intensidades de los píxeles de la imagen y la creación de algoritmos más rápidos (Akole y Kulkarni, 2016; Espinoza-del Angel y Femat-Díaz, 2021; Kurukuru *et al.*, 2019a; Resendiz-Ochoa *et al.*, 2018). El espacio de color CMY se ha utilizado debido a su sencillez para representar el color con mayor influencia en la temperatura (Espinoza-del Angel y Femat-Díaz, 2021; Glowacz y Glowacz, 2017; Glowacz *et al.*, 2017). Los espacios de color HSI, HSV y CIE L*a*b se han usado debido a que se considera que extraen de manera más precisa las características de color en la imagen (Al-Musawi *et al.*, 2020; Espinoza-del Angel y Femat-Díaz, 2021; Haider *et al.*, 2018; Salazar y Macabebe, 2016).

A partir de la selección del espacio de color se extraen datos de tipo cuantitativo de la imagen termográfica. Algunos trabajos basados en el análisis de estos datos utilizan descriptores estadísticos de primer y segundo orden, los cuales son obtenidos a partir de enfoques estadísticos. El primero de ellos es el histograma, el cual, a partir del valor promedio de la distribución del nivel de grises o colores de la imagen, obtiene algunas características de color y textura empleando los descriptores de primer orden de media, desviación estándar, asimetría, curtosis, energía y entropía (Khamisan *et al.*, 2015). El segundo es la matriz de co-ocurrencia, esta permite identificar relaciones espaciales entre los niveles de color de los píxeles de la imagen, extrayendo características de textura aplicando descriptores de segundo orden como contraste, correlación, energía, homogeneidad y entropía (Kurukuru *et al.*, 2019a,1).

Una vez obtenidas las características de la imagen, diversos autores utilizan métodos de clasificación de fallas para la elaboración de los sistemas de detección. Los métodos de clasificación más usados se basan en estadísticas como análisis discriminante lineal (Haider *et al.*, 2018), k-vecinos más cercanos (k-NN, por sus siglas en inglés) (Glowacz y Glowacz, 2017; Glowacz *et al.*, 2017) y naive bayes (NB, por sus siglas en inglés) (Ullah *et al.*, 2020; Umair *et al.*, 2020; Zhang y Fjeld, 2020). En redes neuronales los clasificadores más populares son perceptrón multicapa (MLP, por sus siglas en inglés) (Olivatti *et al.*, 2018; Taheri-Garavand *et al.*, 2015; Ullah *et al.*, 2017) y sistema de inferencia adaptable neuro difuso (ANFIS, por sus siglas en inglés) (Al-Obaidy *et al.*, 2017; Olivatti *et al.*, 2018). Por último, en árboles de decisión (Janssens *et al.*, 2015; Ullah *et al.*, 2020) y máquinas de vectores de soporte (SVM por sus siglas en inglés) (Hui y Fuzhen, 2015; Jadin *et al.*, 2014; Yang *et al.*, 2016).

En el Cuadro 2.1 se muestra un resumen de aplicaciones, en donde se emplearon imágenes termográficas para la creación de sistemas de detección de fallas y degradación de objetos. En la segunda columna se indica el espacio de color utilizado para la extracción de

características de la imagen.

Cuadro 2.1

Aplicaciones de la termografía.

Aplicaciones	Espacio de color	Autores
Paneles solares, equipos eléctricos, transformadores eléctricos, subcapas en componentes electrónicos, unión de soldadura en PCB, diseño de circuitos, cojinetes de motores de inducción, servidores	RGB	(Khamisan et al., 2015; Akole and Kulkarni, 2016; Maciel et al., 2017; Gallardo-saavedra et al., 2019; Mamchur et al.,2020, Wiyosobunri et al.,2020)
Paneles solares, cojinetes de maquinaria rotativa, radiadores de enfriamiento, líneas de energía, tarjetas PCB, detección de fallas y componentes electrónicos, como MOSFET e IGBT, servidores	Escala de grises	(Al-obaigy et al., 2017; Chen et al., 2018; Chen and Yutian, 2018; Resendiz-ochoa et al., 2018; Liu et. al, 2017)
Paneles solares, motores de inducción y equipos eléctricos	HSV	(Haider et al., 2018; Al-Musawi et al., 2020)
Equipos eléctricos	HSI	(Dutta et al., 2016; Suguna et al., 2016)
Motores trifásicos y motores de corriente directa	CMY	(Glowacz et al., 2017; Glowacz and Glowacz, 2017)
Paneles solares	CIE L*a*b	(Salazar and Macabebe, 2016)

Como se puede visualizar en el Cuadro 2.1, los espacios de color más empleados en la elaboración de sistemas de detección de fallas o defectos a través de la termografía infrarroja son el RGB y la escala de grises. El espacio RGB se ha implementado en la detección de anomalías y clasificación de defectos en paneles solares, diagnóstico y clasificación de fallas de equipos eléctricos, evaluación de la unión de soldadura en PCB, detección de defectos en transformadores eléctricos, detección de defectos y análisis de subcapas en componentes electrónicos para la optimización del diseño de circuitos, monitoreo y diagnóstico de fallas

en cojinetes de motores de inducción (Akole y Kulkarni, 2016; Khamisan *et al.*, 2015; Maciel *et al.*, 2017; Olivatti *et al.*, 2018).

La escala de grises es ampliamente utilizada en la detección de defectos y porcentaje de degradación en paneles solares, servidores, detección de fallas en cojinetes de maquinaria rotativa, diagnóstico de fallas y monitoreo de condición en radiadores de enfriamiento, detección de puntos calientes en líneas de energía, fallas en tarjetas PCB, detección de fallas y puntos calientes en componentes electrónicos, como MOSFET e IGBT (Aghaei *et al.*, 2015; Al-Obaidy *et al.*, 2017; Duan *et al.*, 2016; Hui y Fuzhen, 2015; Janssens *et al.*, 2015; Kim *et al.*, 2015; Kurukuru *et al.*, 2019a; Lee *et al.*, 2018b; Liu *et al.*, 2017a; Sarawade y Charniya, 2019; Taheri-Garavand *et al.*, 2015).

Los espacios de color HSV, CMY, HSI y CIE L*a*b son poco usados para la creación de este tipo de herramientas. Entre las aplicaciones del espacio HSV se encuentran la detección y localización de puntos calientes para identificar fallas en paneles solares, monitoreo de estado en motores de inducción, diagnóstico de fallas en equipos eléctricos (Al-Musawi *et al.*, 2020; Alajmi *et al.*, 2019; Haider *et al.*, 2018). El uso del espacio de color CMY ha hecho posible el diagnóstico de fallas de motores trifásicos y motores de corriente directa (Glowacz y Glowacz, 2017; Glowacz *et al.*, 2017). El espacio de color CIE L*a*b se ha utilizado en la detección, localización y cuantificación de áreas críticas con la finalidad de detectar degradación en sistemas fotovoltaicos (Salazar y Macabebe, 2016). Y el espacio de color HSI ha permitido la detección de fallas en equipos eléctricos (Suguna *et al.*, 2016).

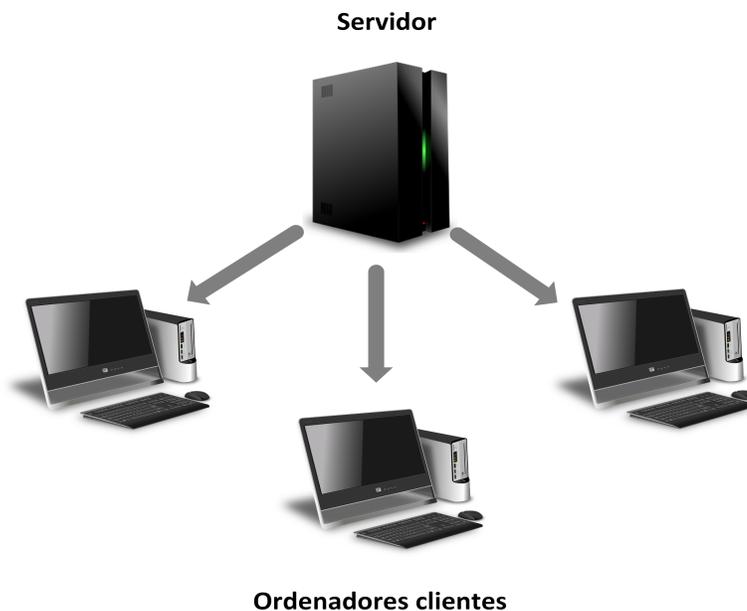
2.2. Marco teórico

2.2.1. Servidor informático

Un servidor es un equipo informático que proporciona recursos de datos, servicios o programas a otros ordenadores llamados clientes, como se visualiza en la Figura 2.1. Exis-

ten diversos tipos de servidores como los de archivos, impresión, aplicaciones, DNS, correo, web, base de datos, virtuales, proxy, supervisión y administración (Zhang y Wang, 2003). La mayoría de los servidores están compuestos por hardware, procesadores, memoria, circuitos integrados, dispositivos de entrada/salida, periféricos, reguladores de voltaje, fuentes de alimentación y sistemas de refrigeración (Jin *et al.*, 2020).

Figura 2.1
Arquitectura cliente-servidor.



2.2.2. Fallas en servidores

La falla del servidor ocurre cuando el dispositivo no se comporta de la manera especificada. Esto puede ocasionar problemas de funcionamiento, interrupciones del servicio y costos de reparación. Las posibles causas de falla pueden originarse en el hardware y el software del servidor o en las instalaciones del centro de datos.

Las fallas más comunes del hardware son el ventilador, la tarjeta de red y memoria, la fuente de alimentación, el disco duro y la CPU. Aproximadamente un 78.8% de las fallas

de un servidor se deben a estos dos últimos componentes (Kumar *et al.*, 2010; Sankar *et al.*, 2013). Las fallas de software pueden ocurrir por diversas razones como, sistema operativo desactualizado, sobrecarga del sistema por tráfico de datos y ataques cibernéticos. Otras razones se deben a las condiciones ambientales como, el sobrecalentamiento del servidor, la humedad, los cortes de energía y los desastres naturales (Pertet y Narasimhan, 2005).

2.2.3. Sistemas de detección de fallas

Un sistema de detección de fallas consiste en identificar una o más causas fundamentales de los problemas hasta tomar acciones correctivas (Altaf *et al.*, 2019). Este se activa al ocurrir una avería y posteriormente se realiza un análisis mediante una variedad de medios cuantitativos o cualitativos (Bagavathiappan *et al.*, 2013; Khamisan *et al.*, 2015). A partir de los datos obtenidos se efectúa un diagnóstico de la falla y, por último, se restablece el proceso como se muestra en la Figura 2.2 (Sharma *et al.*, 2018).

Figura 2.2

Diagrama de flujo de un sistema de detección de fallas.



Estos sistemas evalúan la integridad de un dispositivo utilizando la información obtenida a partir de diversos ensayos destructivos o no destructivos (Hsieh, 2014; Kumar *et al.*, 2017). Los destructivos modifican las propiedades de un producto generando daños que invalidan su uso posterior. Los no destructivos, ocasionan un daño imperceptible o nulo. Estos últimos son los más atractivos para la industria y varían según su tipo de aplicación (Li *et al.*, 2019). Entre los más usados se encuentran los de ultrasonido, visual, acústico, aceites,

radiografía, corrientes parasitas y termografía (Bagavathiappan *et al.*, 2008; Dwivedi *et al.*, 2018; Kumar y Mahto, 2013; Smith, 2015).

2.2.4. Termografía infrarroja

La termografía infrarroja es una técnica que permite medir la temperatura de un equipo sin necesidad de contacto físico (Olivatti *et al.*, 2018). Es utilizada para observar el estado térmico de un cuerpo o la degradación en materiales (Aghaei *et al.*, 2015; Al-Musawi *et al.*, 2020; Chellamuthu y Sekaran, 2019; Janssens *et al.*, 2015). La TI es un conjunto de ondas electromagnéticas de mayor longitud que la luz visible (Usamentiaga *et al.*, 2014), por lo que para visualizarla se requiere del uso de dispositivos como la cámara térmica (Bagavathiappan *et al.*, 2013). Esta capta la radiación por medio del detector y mapea la distribución de temperatura en una imagen visible usando la ley de Stefan-Boltzmann determinada mediante la Ecuación 2.1. Donde q es la tasa de emisión de energía (W), A es el área de la superficie emisora en (m^2), (T) es la temperatura absoluta en Kelvin (K) y σ es igual a la constante de Stefan-Boltzmann ($5.67 * 10^{-8} W/(m^2, K^4)$) (Ahmed *et al.*, 2015; Osornio-Rios *et al.*, 2019; Prakash, 2012; Sun *et al.*, 2019a).

$$\frac{q}{A} = \epsilon \sigma T^4 \tag{2.1}$$

2.2.5. Imagen digital

La imagen digital se define como una función bidimensional $f(x, y)$, donde x, y son coordenadas espaciales y la amplitud de f en cualquier par de coordenadas $f(x, y)$ se llama nivel de gris de la imagen. La Ecuación 2.2 representa la imagen digital como una matriz de números reales, donde x denota las filas y y las columnas (Gonzalez y Woods, 2002). En una imagen digital binaria los valores de la función son 0, 1. En una imagen en escala de grises los valores van desde 0 (negro) a 255 (blanco) y en la imagen a color cada punto es la

combinación de tres bandas dependiendo del espacio de color utilizado.

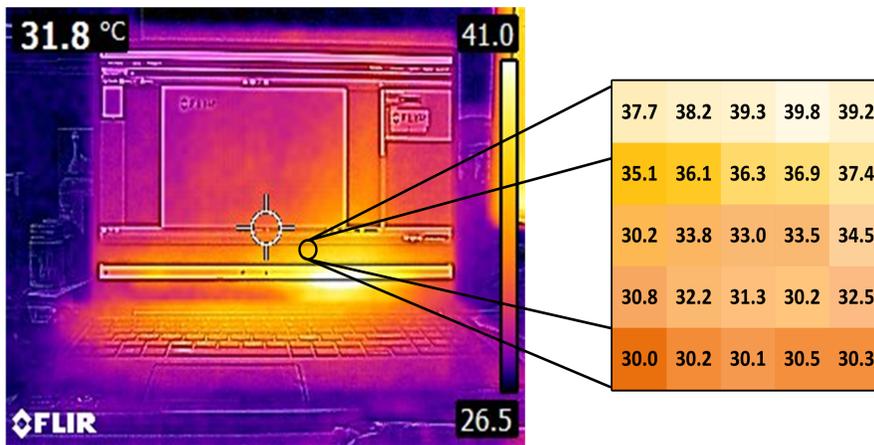
$$f(x,y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0,N-1) \\ f(1,0) & f(1,1) & \dots & f(1,N-1) \\ \vdots & \vdots & & \vdots \\ f(M-1,0) & f(M-1,1) & \dots & f(M-1,N-1) \end{bmatrix} \quad (2.2)$$

2.2.6. Imagen térmica

Una imagen termográfica está representada por un código de color de falsa tonalidad, donde cada tono representa un valor de temperatura como se representa en la Figura 2.3 (Law *et al.*, 2018). En cualquier termograma, los colores más brillantes como rojo, naranja, amarillo o blanco indican temperaturas cálidas. Los tonos púrpuras, azul oscuro o negro indican temperaturas frías o con menor emisión de radiación infrarroja (Cruz-Albarran *et al.*, 2019).

Figura 2.3

Imagen térmica con vista a los datos de temperatura internos.



2.2.7. Tipos de termografía infrarroja

La inspección termográfica se divide en dos categorías, activa y pasiva (Maldague, 1993; Sanati *et al.*, 2018). La pasiva implica la detección de imágenes térmicas sin necesidad de una fuente de energía externa. Esto debido a que el objeto de estudio puede generar calor por sí mismo como se aprecia en la Figura 2.4 (Aghaei *et al.*, 2015; Alajmi *et al.*, 2019; Olivatti *et al.*, 2018; Salazar y Macabebe, 2016). La termografía pasiva es ampliamente utilizada en el monitoreo de condición de dispositivos o procesos industriales (Holland y Reusser, 2016).

Figura 2.4

Esquema para el monitoreo de condición basado en TI pasiva.



La activa se emplea cuando se requiere de energía externa para producir un contraste térmico (Ver Figura 2.5). Las técnicas más utilizadas para producir calor son, la vibración, la fase pulsada, el bloqueo, las corrientes parásitas y la inducción (Bagavathiappan *et al.*, 2013; Holland y Reusser, 2016). Este método de inspección se usa para obtener el estado de degradación de un material (Ibarra-Castanedo *et al.*, 2007).

Ambos tipos permiten un estudio cualitativo y cuantitativo. El primero es usado para detectar la presencia de una anomalía observando los colores de la imagen térmica. El segundo emplea el uso del procesamiento de imágenes para obtener características de la imagen que son útiles para efectuar un diagnóstico (Ibarra-castanedo y Maldague, 2013;

Figura 2.5

Esquema para la detección de degradación de un material basado en TI activa.



Shawal y Taib, 2012).

2.2.8. Aplicaciones de la TI pasiva en la industria

El uso de la termografía infrarroja se puede clasificar en tres principales aplicaciones, mecánicas, eléctricas y electrónicas (Osornio-Rios *et al.*, 2019). El área de la ingeniería eléctrica cubre un gran número de aplicaciones relacionadas con el sector industrial. Sus usos más comunes son, la visualización de sobrecalentamiento, las conexiones defectuosas, los aislamientos inadecuados y la degradación del empaque o delaminación (Alajmi *et al.*, 2019; Arellano y Morales, 2015; Maciel *et al.*, 2017; Palimkar y Bhole, 2016; Ullah *et al.*, 2017; Wang y Zhao, 2019). Los dispositivos que se han evaluado con esta técnica son, instalaciones eléctricas, transformadores, líneas de transmisión, subestaciones eléctricas y paneles solares (Ahmed *et al.*, 2015; Dutta *et al.*, 2016; Huda y Taib, 2013; Huda *et al.*, 2012; Jadin *et al.*, 2014,1; Suguna *et al.*, 2016; Wronkowitz, 2016).

Las principales aplicaciones mecánicas de TI se centran en evaluar la integridad estructural de la maquinaria, determinar el desgaste de herramientas o piezas mecánicas, localizar obstrucciones y conexiones sueltas o fugas (Choudhary *et al.*, 2018; Glowacz y Glowacz, 2017; Khamisan *et al.*, 2015; Resendiz-Ochoa *et al.*, 2018; Taheri-Garavand *et al.*, 2015). Entre los dispositivos estudiados se encuentran, motores de inducción, maquinaria rotativa,

radiadores de enfriamiento y motores de corriente directa (Al-Musawi *et al.*, 2020; Glowacz y Glowacz, 2017; Glowacz *et al.*, 2017; Janssens *et al.*, 2015; Khamisan *et al.*, 2015; Luqman *et al.*, 2018; Taheri-Garavand *et al.*, 2015).

En los últimos años, el uso de termografía pasiva en componentes electrónicos ha ido en aumento. Esta es utilizada para realizar perfilado térmico, localizar puntos calientes o detectar fallas como, cortocircuito, polaridad de voltaje, tierra inversa, falta de componentes; y sobrevoltaje (Alaoui *et al.*, 2019; Sarawade y Charniya, 2019; Stoyanova *et al.*, 2018; Sun *et al.*, 2019a). Los dispositivos electrónicos más explorados son, transistores MOSFET e IGBT, circuitos integrados, diodos, condensadores, tarjetas electrónicas y servidores (Akole y Kulkarni, 2016; Al-Obaidy, 2016; Andonova *et al.*, 2014; Chen *et al.*, 2018; Liu *et al.*, 2019,1; Mahfurdz *et al.*, 2020; Stoyanova *et al.*, 2018; Sun *et al.*, 2019a).

2.2.9. Metodología para la detección de fallas mediante TI pasiva

El desarrollo de un sistema de diagnóstico automatizado mediante termografía pasiva generalmente consta de cinco etapas principales, adquisición y procesamiento de imágenes, extracción y selección de características; y clasificación (Duan *et al.*, 2016; Shawal y Taib, 2012). La metodología se ilustra en la Figura 2.6.

Figura 2.6
Metodología para la detección de fallas mediante TI.



2.2.9.1. Adquisición de imágenes

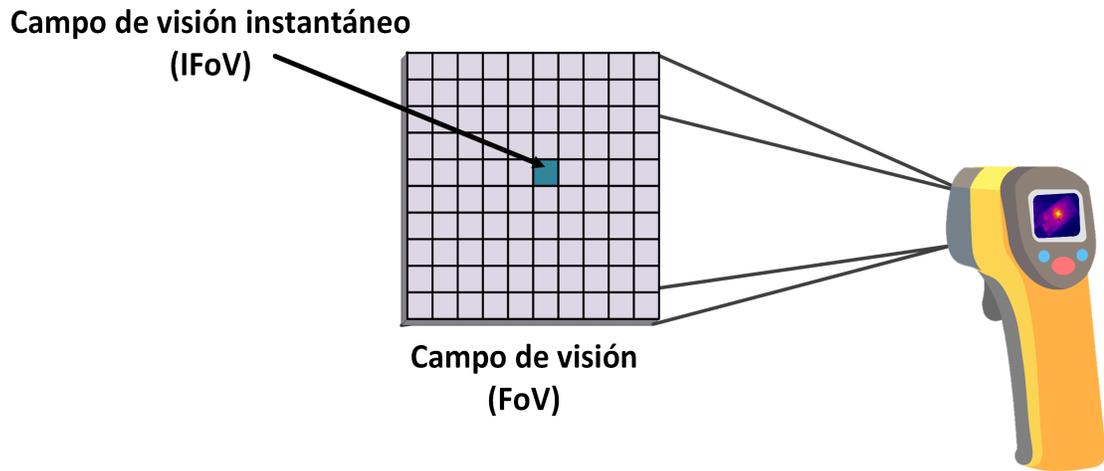
La adquisición de imágenes consiste en capturar el termograma del objeto de estudio. En esta etapa es fundamental tomar en cuenta diversas características de la cámara, la posición de captura y la emisividad (Espinoza-del Angel y Femat-Díaz, 2021; Huda y Taib, 2013; Nunak *et al.*, 2015).

El rango de temperatura de la cámara debe ser seleccionado de acuerdo con la capacidad calorífica del dispositivo que se desea examinar. Otro aspecto a considerar es el lente óptico, debido a que la eficiencia de transmisión infrarroja es determinada por los materiales utilizados para su fabricación (FLIR Systems Inc., 2011; Nunak *et al.*, 2015). El germanio es el material más eficiente para transmitir energía al detector. Así mismo, se debe tomar en cuenta su resolución. Una mayor cantidad de píxeles enfocados en el objeto capturará una imagen con una medición más precisa y con mayor detalle (FLIR Systems Inc., 2011).

El campo de visión (FoV, por sus siglas en inglés) es otro aspecto a considerar, ya que define el área visible en una imagen a largas distancias (Nunak *et al.*, 2015). Además, se debe tomar en cuenta el campo de visión instantáneo (IFoV, por sus siglas en inglés) debido a que define el tamaño de objeto más pequeño detectado en el campo de visión a una distancia establecida (Ver Figura 2.7) (Dziarki *et al.*, 2019; Gyorok y Beszedes, 2019). La fórmula del IFoV puede determinarse con la Ecuación 2.3, donde f es ángulo focal y d es el tamaño del detector (FLIR Systems Inc., 2018).

$$IFoV = 2 * \arctan \left(\frac{d}{2 * f} \right) \quad (2.3)$$

Figura 2.7
Campo de visión instantáneo (IFoV).



La emisividad es un factor externo que afecta la precisión de las mediciones. Se define como la capacidad de un objeto para irradiar calor (Marinetti y Cesaratto, 2012; Rahrueangdet *et al.*, 2016). Es la relación entre la cantidad de radiación emitida por una superficie y la emitida por el objeto, representada por la Ecuación 2.4 (Vollmer y Möllmann, 2018). Los valores de emisividad van de 0 (espejo térmico) a 1 (radiador perfecto) (Marinetti y Cesaratto, 2012). Este valor varía dependiendo de propiedades físicas y químicas de los materiales, como temperatura, longitud de onda, ángulo, oxidación, rugosidad o tratamiento térmico. Al capturar una imagen, la emisividad debe ser compensada utilizando cintas aislantes, pinturas o líquido corrector blanco (Alaoui *et al.*, 2019; Marinetti y Cesaratto, 2012). Si no se corrige la cámara detectará la temperatura reflejada en el ambiente (Mamchur *et al.*, 2020; Resendiz-Ochoa *et al.*, 2018).

$$\varepsilon = \frac{N_{\lambda,T}}{E_b} \quad (2.4)$$

2.2.9.2. Procesamiento de imágenes

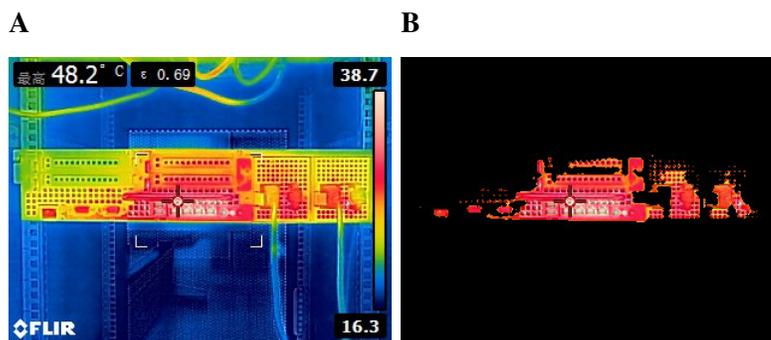
El procesamiento de imágenes son un conjunto de herramientas matemáticas que se aplican a las imágenes digitales con el objetivo de mejorar la calidad o extraer información (Dong y Chen, 2019). En una imagen térmica, las técnicas más utilizadas son, la segmentación y la conversión entre espacios de color o escala de grises (Aghaei *et al.*, 2015; Jadin *et al.*, 2014; Palimkar y Bhole, 2016).

2.2.9.2.1 Segmentación de la región de interés

La extracción de la región de interés separa el área del objeto del resto de la imagen (Jadin *et al.*, 2015). Se puede hacer recortando la imagen o mediante la segmentación (Widodo *et al.*, 2011). La Figura 2.8 muestra la segmentación de un objeto en una imagen térmica. Esta técnica divide el primer plano del fondo de la imagen para localizar objetos o bordes. Se efectúa agrupando los píxeles según su similitud de color o forma (Palimkar y Bhole, 2016). Las técnicas de segmentación más usadas son Roberts, Prewitt, Canny, Sobel y Otsu (Haider *et al.*, 2018). Los métodos de segmentación Roberts, Prewitt, Canny y Sobel detectan los bordes que delimitan a los objetos. El método de Otsu separa la región deseada al establecer un valor de umbral (Hinojosa *et al.*, 2018).

Figura 2.8

Ejemplo de imagen térmica segmentada.



Nota. A: Imagen original , B: Imagen segmentada.

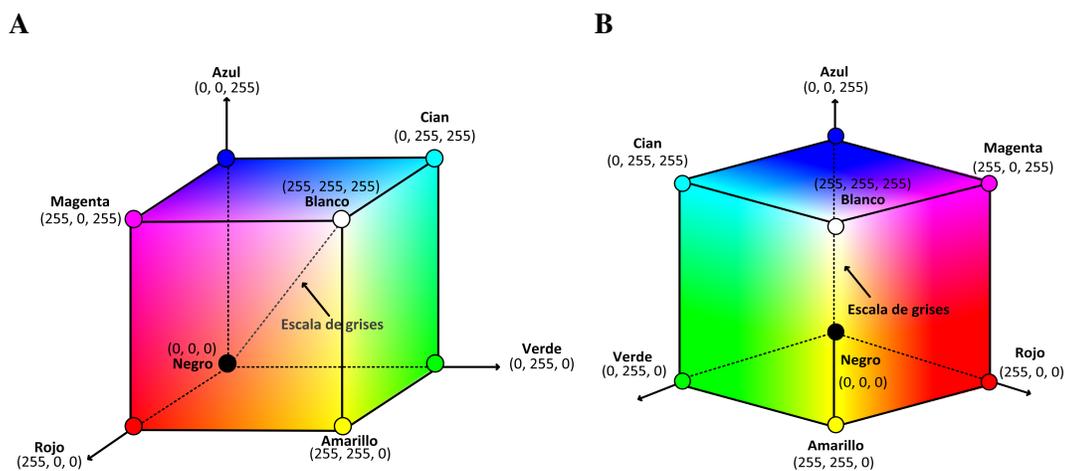
2.2.9.2.2 Espacios de color

Un modelo de color o espacio de color se puede definir como una representación matemática de una gama de colores (Gonzalez y Woods, 2002; McAndrew, 2015). Existen diversos espacios de color como, RGB, HSI, HSV, CMY, CIE L*a*b, etc.

El espacio RGB es un modelo de color aditivo que combina los colores primarios rojo, verde y azul (Rhyne, 2017). Se basa en el sistema cartesiano de coordenadas de tres dimensiones como se aprecia en la Figura 2.9A. El rojo, el verde y el azul se encuentran ubicados en las coordenadas $(1,0,0)$, $(0,1,0)$ y $(0,0,1)$, respectivamente. El cian se encuentra en el vértice $(0,1,1)$, el magenta en $(1,0,1)$ y el amarillo en $(1,1,0)$. El color negro está en el punto de origen del sistema y el blanco en contra esquina. La escala de grises se ubica en la diagonal que va de negro a blanco. La gama de color son los puntos ubicados dentro del cubo. El CMY es igual al modelo RGB visto desde otra perspectiva, se basa en los colores primarios sustractivos cian, magenta y amarillo como se aprecia en la Figura 2.9B. La mezcla de estos tres colores da como resultado el color negro y el resto de los colores se obtiene al combinar cada uno de los colores secundarios (Pratt, 2007; Rhyne, 2017).

Figura 2.9

Sistema cartesiano tridimensional de los espacios de color RGB y CMY.



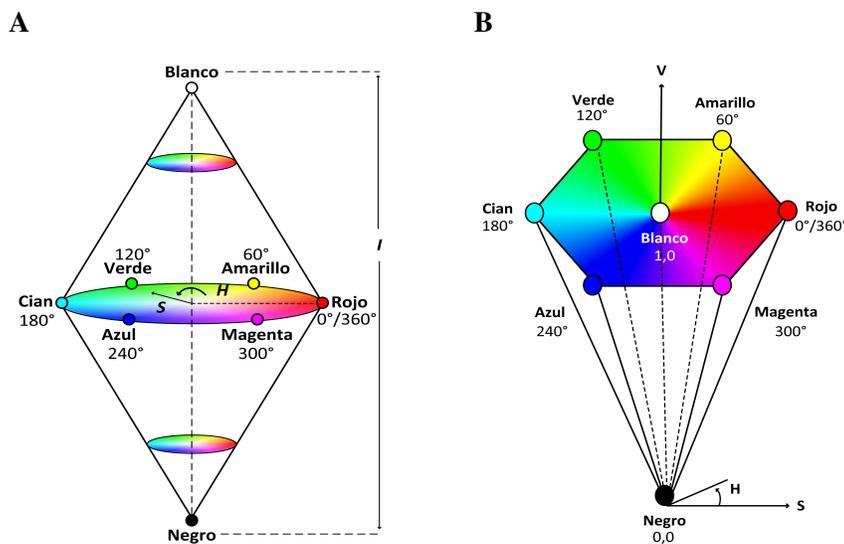
Nota. A: Modelo RGB , B: Modelo CMY.

El espacio HSI es una transformación no lineal del modelo RGB en coordenadas cilíndricas tridimensionales (ver Figura 2.10A). El matiz (H) es usado para describir el color y va en un ángulo de 0° a 360° . Comienza y termina en rojo ($0/360^\circ$) y contiene los colores, amarillo (60°), verde (120°), cian (180°), azul (240°) y magenta (300°). La saturación (S) indica el grado en el que un tono difiere del gris neutro y va desde 0% (sin color) hasta 100% (color puro). La intensidad es el brillo del matiz y varía respecto a la saturación del color, donde 0% denota un color negro y 100% la existencia de colores (Gonzalez y Woods, 2002; Rhyne, 2017).

El modelo HSV es una representación tridimensional hexagonal, donde el eje central representa la intensidad o valor (V), como se aprecia en la Figura 2.10B. Al igual que el HSI, el tono o matiz es un ángulo en el rango 0° a 360° grados; y la saturación y valor varían de 0% a 100%. Los espacios de HSI y HSV desacoplan la banda de intensidad o valor de la información que transporta el color (matiz y saturación) en una imagen (Chaki y Dey, 2020; Ibraheem *et al.*, 2012).

Figura 2.10

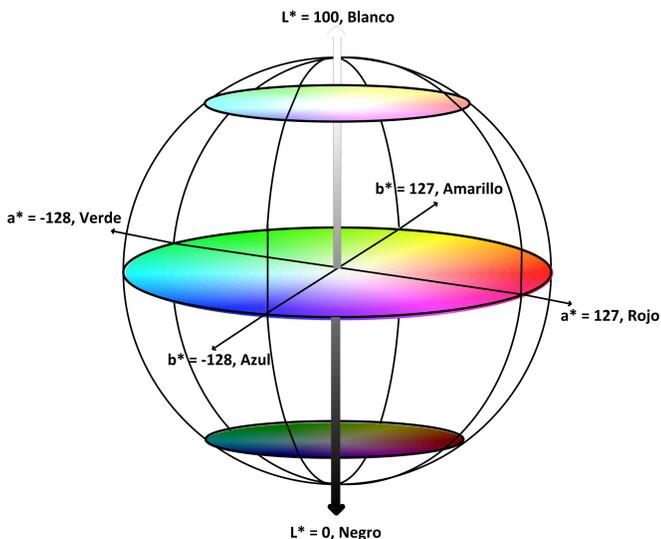
Representación tridimensional de modelos de color HSI y HSV.



Nota. A: Modelo HSI , B: Modelo HSV.

CIE $L^*a^*b^*$ es un espacio de color oponente tridimensional (ver Figura 2.11). Se basa en la teoría de oposición que explica aspectos del procesamiento del color al transferirse del ojo al cerebro humano (Rhyne, 2017). Está compuesto por tres componentes, el eje L que traza la luminosidad de blanco a negro. Los componentes a^* y b^* son ejes de coordenadas cromáticas, a^* toma valores entre rojo y verde, y b^* considera valores entre amarillo y azul (Gonzalez y Woods, 2002).

Figura 2.11
*Representación del espacio de color CIE $L^*a^*b^*$.*



2.2.9.2.3 Escala de grises

El término nivel de gris o escala de grises es usado para denotar la intensidad de la luz monocromática. A cada color se le asigna un valor que varía gradualmente en intensidad de grises y va desde el negro hasta el blanco, como se muestra en la Figura 2.12 (Gonzalez y Woods, 2002; McAndrew, 2015). Generalmente, las imágenes digitales en escala de grises emplean 8 bits para representar cada píxel, lo que solo permite una escala con 256 intensidades de tonalidades diferentes.

Figura 2.12

Representación de la escala de grises.



2.2.9.2.4 Conversión RGB a otros espacios de color o escala de grises

Los termogramas son adquiridos en el espacio RGB, por ello se necesita realizar transformaciones matemáticas para traducir la representación del color de un espacio a otro (Chaki y Dey, 2020). Para transformar una imagen RGB a CMY se aplica la Ecuación 2.5. Esta supone que todos los valores de color RGB se han normalizado en un rango [0,1] y es calculada por cada píxel contenido la imagen (Gonzalez y Woods, 2002).

$$\begin{bmatrix} C \\ M \\ Y \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} - \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.5)$$

La conversión del espacio RGB a HSI se realiza usando las Ecuaciones 2.6 a 2.8. Donde $H = 360^\circ - H$ si, $(B/I) > (G/I)$ y min es el valor mínimo de los componentes R, G y B.

$$H = \cos^{-1} \left[\frac{\frac{1}{2}[(R-G) + (R-B)]}{[(R-G)^2 + (R-B)(G-B)]^{\frac{1}{2}}} \right] \quad (2.6)$$

$$S = 1 - \frac{3}{(R+G+B)} [\min(R, G, B)] \quad (2.7)$$

$$I = \frac{1}{3}(R+G+B) \quad (2.8)$$

Para calcular un punto en el sistema de coordenadas RGB a su valor correspondiente en el espacio HSV, son utilizadas las Ecuaciones 2.9 a 2.13. Donde R, G y B son las coordenadas rojo, verde y azul, y sus valores son números reales entre [0, 255] (Chaki y Dey, 2020).

$$H = \cos^{-1} \left[\frac{\frac{1}{2}[(R-G) + (R-B)]}{[\sqrt{(R-G)^2 + (R-B)(G-B)}]} \right] \quad (2.9)$$

$$H = H, \text{ si } B \leq G \quad (2.10)$$

$$H = 360 - H, \text{ si } B > G \quad (2.11)$$

$$S = \frac{\max(R, G, B) - \min(R, G, B)}{\max(R, G, B)} \quad (2.12)$$

$$V = \frac{\max(R, G, B)}{255} \quad (2.13)$$

Para traducir una imagen RGB a CIE L*a*b, primero se calcula la iluminante de referencia y las coordenadas primarias RGB expresadas en un sistema de valores triestímulo como el CIE XYZ usando la Ecuación 2.14. Donde los valores de RGB se encuentran normalizados en el rango [0,1] y los valores dentro de la matriz son la iluminante estándar (Rhyne, 2017). A partir de las componentes XYZ, las componentes L*a*b se obtienen mediante las Ecuaciones 2.15 a 2.17. Donde X_w , Y_w , Z_w son valores triestímulo de un punto blanco de referencia.

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0,4124564 & 0,3575761 & 0,1804375 \\ 0,2126729 & 0,7151522 & 0,0721750 \\ 0,0193339 & 0,1191920 & 0,9503041 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.14)$$

$$L^* = 116 \left(\frac{Y}{Y_w} \right)^{\frac{1}{3}} - 16 \quad (2.15)$$

$$a^* = 500 \left[\left(\frac{X}{X_w} \right)^{\frac{1}{3}} - \left(\frac{Y}{Y_w} \right)^{\frac{1}{3}} \right] \quad (2.16)$$

$$b^* = 200 \left[\left(\frac{Y}{Y_w} \right)^{\frac{1}{3}} - \left(\frac{Z}{Z_w} \right)^{\frac{1}{3}} \right] \quad (2.17)$$

Los valores RGB se convierten a escala de grises mediante la Ecuación 2.18. Donde $g(x,y)$ representa la imagen obtenida en escala de grises; R, G y B son los componentes de

entrada rojo, verde y azul; y 0.2989, 0.5870, 0.1140 son los coeficientes de percepción de intensidad para R, G y B respectivamente.

$$g(x,y) = \begin{bmatrix} R(x,y) \\ G(x,y) \\ B(x,y) \end{bmatrix} * \begin{bmatrix} 0,2989 \\ 0,5870 \\ 0,1140 \end{bmatrix} \quad (2.18)$$

2.2.9.3. Extracción de características

La extracción de características consiste en transformar la información contenida en la imagen en valores numéricos utilizables para el aprendizaje automático (Dutta *et al.*, 2019; Ghoghogh *et al.*, 2019; Jadin *et al.*, 2014; Ma y Yuan, 2019). Los descriptores estadísticos de primer orden como, media, varianza, desviación estándar, asimetría, energía y entropía obtienen información sobre la disposición espacial del color o las intensidades de los píxeles de una región (Khamisan *et al.*, 2015). Se calculan utilizando las Ecuaciones 2.19 a 2.24 (Gonzalez y Woods, 2002; Taheri-Garavand *et al.*, 2015). Donde, Z es la variable aleatoria que indica la intensidad, $p(Z_i), i=0,1,2,\dots,L-1$ corresponde al histograma normalizado y L la cantidad de niveles de intensidad distintos.

$$Media = \sum_{i=0}^{L-1} Z_i P(Z_i) \quad (2.19)$$

$$Varianza = \sum_{i=0}^{L-1} (Z_i - m)^n P(Z_i) \quad (2.20)$$

$$Desviación\ estándar = \sqrt{\sum_{i=0}^{L-1} (Z_i - m)^2 P(Z_i)} \quad (2.21)$$

$$Asimetría = \sum_{i=0}^{L-1} (Z_i - m)^3 P(Z_i) \quad (2.22)$$

$$Energía = \sum_{i=0}^{L-1} P^2(Z_i) \quad (2.23)$$

$$Entropía = \sum_{i=0}^{L-1} P(Z_i) \log_2 P(Z_i) \quad (2.24)$$

La media describe la intensidad promedio de una región. La varianza y la desviación estándar son una medida de variabilidad de la intensidad de los píxeles (Chaki y Dey, 2020; Dutta *et al.*, 2019; Rhyne, 2017). La asimetría proporciona información del sesgo de los niveles de intensidad (lado oscuro o claro de la media). La energía describe la cantidad de uniformidad o textura gruesa en la imagen. La entropía mide la distribución de probabilidad de la intensidad de píxeles, una gran cantidad de píxeles con la misma intensidad indica una baja entropía (Dutta *et al.*, 2019; Gonzalez y Woods, 2002; Huda y Taib, 2013).

2.2.9.4. Selección de variables

La selección de variables es el proceso de determinar las variables o características que son relevantes para una clase (Ghojogh *et al.*, 2019; Parhizkar *et al.*, 2021). El rendimiento de la clasificación puede degradarse si no eligen correctamente. Algunas técnicas que reducen la cantidad de variables o determinan las variables significativas en un modelo de

predicción son, el análisis de regresión y el análisis de componentes principales (Dutta *et al.*, 2019; Ghogh *et al.*, 2019).

2.2.9.4.1 Análisis de regresión

El análisis de regresión es un modelo matemático que determina la relación entre variables dependientes e independientes. Existen dos tipos de análisis de regresión, simple y múltiple. La simple tiene solo una variable independiente, mientras que la regresión múltiple puede tener dos o más variables independientes (Sarstedt y Mooi, 2019)

La regresión simple se representa en la Ecuación 2.25. Donde, y es la variable dependiente, x la variable independiente, a la pendiente que expresa el cambio de y ocasionado por x y b es la constante que indica el valor promedio de y cuando x es cero (Freund *et al.*, 2006).

$$y = ax + b \tag{2.25}$$

La ecuación de regresión múltiple se visualiza en la expresión 2.26. Donde, la variable dependiente y , se interpreta como una combinación lineal de un conjunto de k variables independientes. β_k mide el cambio unitario en y respecto a x_k . Este coeficiente indica el peso relativo de la variable en un modelo matemático. El factor ε determina el error aleatorio que no puede ser explicado por la relación entre x_k y y (Lee *et al.*, 2015; Parhizkar *et al.*, 2021).

$$y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \dots + \beta_kx_k + \varepsilon \tag{2.26}$$

En ambos tipos de regresión, la manera en la que se relaciona la variable dependiente e independiente puede darse de forma lineal, exponencial, potencial, polinómica, logarítmica, etc.

2.2.9.4.2 Regresión logística

La regresión logística es un método de regresión que permite estimar la probabilidad de una variable dependiente cualitativa en función de una variable independiente cuantitativa. La regresión logística binaria se utiliza cuando la variable dependiente es dicotómica, y si la variable dependiente contiene más de dos categorías se usa la regresión logística multinomial.

Los modelos de regresión logística tienen tres finalidades, cuantificar la relación existente entre las variables dependiente e independiente, identificar interacciones y clasificar individuos dentro de las categorías de la variable dependiente. El objetivo de la regresión logística es predecir la probabilidad de que ocurra y y conocidos los valores de las variables x . La Ecuación 2.27 muestra el modelo matemático general de la regresión logística (Freund *et al.*, 2006). Donde $P(y)$ es la probabilidad de que ocurra y , e es la función exponencial y el resto de los coeficientes son los de la regresión lineal.

$$P(y) = \frac{e^{(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k)}}{1 + e^{(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k)}} \quad (2.27)$$

2.2.9.4.3 Regresión logística penalizada

En cualquier tipo de análisis de regresión, los datos deben cumplir con algunos supuestos como la linealidad, la independencia, la homocedasticidad, la normalidad y la no colinealidad. Este último se considera uno de los problemas más importantes, debido a que la colinealidad puede incrementar la varianza de los coeficientes de regresión, haciéndolos inestables. Para minimizar el impacto de esto, se utilizan estrategias de regularización como la selección de operadores y contracción del menor absoluto (LASSO por sus siglas en inglés “Least Absolute Shrinkage and Selection Operator”) (Gupta *et al.*, 2017).

Este método fuerza que los coeficientes del modelo tiendan a cero, reduciendo el efecto de correlación entre predictores y la influencia de las variables menos relevantes en el modelo (Gupta *et al.*, 2017; Kwon *et al.*, 2013). Las variables con coeficiente de regresión igual a cero no influyen en el modelo, por lo que este análisis consigue excluir aquellos predictores sin relevancia.

En la regularización LASSO el grado de penalización está controlado por el hiperparámetro λ . Cuando $\lambda = 0$, el resultado es equivalente al de un modelo lineal por mínimos cuadrados ordinarios. A medida que λ aumenta, mayor es la penalización y más predictores quedan excluidos. La Ecuación 2.28 es utilizada para realizar la penalización del tamaño absoluto de los coeficientes de regresión. Donde, $\|y - x\beta\|_2^2$ es el término de mínimos cuadrados del modelo de regresión y $\lambda\|\beta\|_1$ es el parámetro que controla la fuerza de la penalización (Kwon *et al.*, 2013; Tibshirani, 1996).

$$\hat{\beta}^{LASSO} = \arg \max_{\beta} \|y - x\beta\|_2^2 + \lambda\|\beta\|_1 \quad (2.28)$$

2.2.9.4.4 Análisis de componentes principales

El análisis de componentes principales es una técnica estadística que reduce la dimensionalidad de un conjunto de datos mientras conserva la mayor parte de la variación en el (Abdi y Williams, 2010; Ringnér, 2008; Sun *et al.*, 2019b). Su principal objetivo es extraer la información relevante de una matriz de datos y comprimir esta información expresándola en un nuevo conjunto de variables ortogonales llamadas componentes principales. Estas se caracterizan por estar no correlacionadas entre sí y se ordenan de acuerdo a la cantidad de varianza que contiene la componente (Abdi y Williams, 2010; Parhizkar *et al.*, 2021).

El primer paso del análisis consiste en la estandarización de una matriz $n \times m$. Esta contiene por columnas las variables y por filas los resultados de las muestras (Janecek *et al.*, 2008; Lee *et al.*, 2015). La estandarización de los datos se realiza a un promedio de 0 y una desviación estándar de 1 usando la Ecuación 2.29 (Liu *et al.*, 2017b). Donde X_{js} representa el valor estandarizado, X_j es el valor a estandarizar y μ_x son el promedio y la desviación estándar σ_x por columna, respectivamente.

$$X_{js} = \frac{X_j - \mu_x}{\sigma_x} \quad (2.29)$$

A partir de la matriz resultante se calcula una matriz de covarianza entre pares de características utilizando la Ecuación 2.30. Donde μ_{jk} es la covarianza entre dos variables, X_j representa el valor de la variable j estandarizada, μ_j es el promedio de la columna de la variable j , X_k es el valor de la variable k estandarizada, μ_k es el promedio de la columna de la variable k , y n es el recuento de datos en la columna. El producto de la Ecuación 2.30 se representa en la expresión 2.31. Donde, $Cov_{i,j}$ es la covarianza entre los elementos en la fila i y la columna j .

$$\sigma_{jk} = \frac{1}{n} \sum_{i=1}^n (X_j - \mu_j)(X_k - \mu_k) \quad (2.30)$$

$$C = \begin{bmatrix} \mu_{1,1} & Cov_{1,2} & \cdots & Cov_{1,m} \\ Cov_{2,1} & \mu_{2,2} & \cdots & Cov_{2,m} \\ \vdots & \vdots & \ddots & \vdots \\ Cov_{n,1} & Cov_{n,2} & \cdots & \mu_{n,m} \end{bmatrix} \quad (2.31)$$

De la matriz resultante se realiza la descomposición de los eigenvalores (λ_k) y los eigenvectores (V_k) utilizando las Ecuaciones 2.32 y 2.33, respectivamente. En esta I representa una matriz identidad. Por último, los λ_k se ordenan de forma descendente, de tal forma que el eigenvector con el eigenvalor más alto se considera como el primer componente principal (Al-Obaidy, 2016).

$$\det(\lambda I - C) = 0 \quad (2.32)$$

$$(\lambda_k I - c) * v_k = 0 \quad (2.33)$$

2.2.9.5. Clasificación

La clasificación es utilizada para predecir la clase de nuevas instancias sin etiqueta. Esta considera la información disponible de un conjunto de variables para definir el patrón

de comportamiento de una o varias clases (Aujeszky *et al.*, 2017; Sharma y Kaur, 2013). Su aprendizaje de reconocimiento puede ser supervisado o no supervisado. El supervisado se basa en generar conocimiento a partir de un conjunto de datos de entrenamiento. El no supervisado, parte de datos no etiquetados previamente (Batta, 2020; Saravanan y Sujatha, 2018). Existe diversos métodos de clasificación, entre los más usados se encuentran los basados en redes neuronales, árboles de decisión, máquinas de vector de soporte y estadística (Lo *et al.*, 2019; Paolanti y Frontoni, 2020).

2.2.9.5.1 Clasificación estadística

En la clasificación estadística se realizan suposiciones sobre las funciones de densidad entre las clases de patrones (Jain *et al.*, 2000; Raudys, 2001; Webb, 2002). Su sistema de identificación está compuesto por el entrenamiento y la clasificación. La fase de entrenamiento o aprendizaje consiste en seleccionar las características más relevantes para representar los patrones de entrada. En la clasificación o prueba se asigna una clase de pertenencia dependiendo de la similitud del nuevo dato y el patrón de entrada (Jain *et al.*, 2000; Sharma y Kaur, 2013). Los clasificadores estadísticos más usados en el reconocimiento de patrones de imágenes térmicas son análisis discriminante lineal, Naive Bayes y k-NN (Bijalwan *et al.*, 2014).

2.2.9.5.1.1 K-vecinos más cercanos

El método k -vecinos más cercanos clasifica un dato de entrada en función de la clase más frecuente a la que pertenecen sus k vecinos más cercanos (Bijalwan *et al.*, 2014). El número de k vecinos a incluir en el proceso de votación se obtiene usando la Ecuación 2.34. Donde N representa los datos totales del conjunto de entrenamiento (Liu *et al.*, 2022).

$$k = \sqrt{N} \tag{2.34}$$

Para predecir la categoría más cercana, se calcula la distancia entre los datos de prueba y los de la entrada. Las funciones de distancia más utilizadas son, Euclidiana y Manhattan (Chomboon *et al.*, 2015; Mulak y Talhar, 2015). Para calcularlas se usan las Ecuaciones 2.35 y 2.36. Donde d_{ij} es la distancia entre los casos i y j , X_{ki} es el valor de la variable X_k para el caso i y X_{kj} es el valor de la variable X_k para el caso j . El vector resultante se ordena de menor a mayor, de tal forma que la distancia más pequeña se considera como el k vecino más cercano (Kurukuru *et al.*, 2019b; Umair *et al.*, 2020).

$$Ed_{ij} = \sqrt{\sum_{k=1}^n (X_{ki} - X_{kj})^2} \quad (2.35)$$

$$Md_{ij} = \sqrt{\sum_{k=1}^n |X_{ki} - X_{kj}|} \quad (2.36)$$

2.2.10. Métricas de desempeño para clasificadores

El desempeño de un algoritmo de clasificación se evalúa mediante diversas métricas como, exactitud, sensibilidad, especificidad y precisión. La exactitud mide el porcentaje de valores que se han clasificado correctamente frente al total de casos examinados (Ecuación 2.37) (Borja-Robalino *et al.*, 2020; Tharwat, 2018). La precisión calcula la proporción entre los casos positivos bien clasificados y el total de predicciones positivas (Ecuación 2.38). La sensibilidad es una medida que permite conocer la proporción de casos positivos que fueron correctamente clasificados (Ecuación 2.39). La especificidad es la proporción entre los casos negativos bien clasificados, respecto al total de negativos y se calcula con la Ecuación 2.40

(Shobha y Rangaswamy, 2018; Tharwat, 2018). En un modelo perfecto la sensibilidad y la especificidad son igual a 1. Para las Ecuaciones 2.37 a 2.40, VP son los verdaderos positivos, VN los verdaderos negativos, FN los falsos negativos y FP los falsos positivos (Mboo y Hameyer, 2016).

$$Exactitud = \frac{VP + VN}{VP + VN + FP + FN} \quad (2.37)$$

$$Precisión = \frac{VP}{VP + FP} \quad (2.38)$$

$$Sensibilidad = \frac{VP}{VP + FN} \quad (2.39)$$

$$Especificidad = \frac{VN}{VN + FP} \quad (2.40)$$

Una matriz de confusión es una herramienta que permite el cálculo de estos parámetros (Raschka, 2014; Shobha y Rangaswamy, 2018). Es una representación matricial donde se visualizan los resultados de las predicciones de una prueba binaria (Ver Figura 2.13). En esta, las filas pertenecen a la clase predicha y las columnas a la clase real (Borja-Robalino *et al.*, 2020).

Figura 2.13
Modelo de la matriz de confusión.

		Valores Reales	
		Positivo	Negativo
Valores de Predicción	Positivo	Verdadero Positivo (VP)	Falso Positivo (FP)
	Negativo	Falso Negativo (FN)	Verdadero Negativo (VN)

2.2.11. Métodos estadísticos de comparación múltiple

Las comparaciones múltiples estiman el grado de diferencia de dos o más tratamientos. El contraste de hipótesis parte de un supuesto de igualdad. Bajo este, la diferencia observada entre tratamientos será debida al error aleatorio o de muestreo (Gutierrez y Roman, 2009; McHugh, 2011). Si la probabilidad del estadístico es inferior a un determinado p-valor (comúnmente 0.05), se asume que la diferencia es lo suficientemente baja como para rechazar la hipótesis nula. El método más común de comparación de medias de dos o más grupos es el análisis de varianza de una vía (ANOVA, por sus siglas en inglés). Este análisis suele usarse en conjunción con el método de Tukey (Gutierrez y Roman, 2009; Kim, 2017).

2.2.11.1. Análisis de varianza de una vía

En el análisis de varianza, la hipótesis fundamental a probar al comparar tratamientos está representada por la Ecuación 2.41. A partir de ella se decide si los tratamientos son iguales estadísticamente, frente a la alternativa de que al menos dos medias son diferentes (Gutierrez Pulido y De la Vara Salazar, 2008; Hesamian, 2016; Kim, 2017).

$$H_0 : \mu_1 = \mu_2 = \mu_3 = \mu_k \quad (2.41)$$

$$H_A : \mu_1 \neq \mu_2 \neq \mu_3 \neq \mu_k$$

El ANOVA consiste en obtener un estadístico llamado F que determina entre un grupo de variables independientes si al menos una de ellas tiene capacidad de explicar una parte significativa de la variación en la variable dependiente (Diez *et al.*, 2010). El estadístico F puede ser obtenido mediante la Ecuación 2.42. Donde MSG y MSE miden la variabilidad entre grupos y dentro de los grupos, respectivamente (Diez *et al.*, 2010; Hesamian, 2016).

$$F = \frac{CM_{TRAT}}{CM_E} \quad (2.42)$$

Para obtener F , primero se calcula la suma total de cuadrados o variabilidad total de los datos usando la Ecuación 2.43. Después se obtienen la suma de cuadrados de los tratamientos y del error, los cuales determinan la variabilidad debida a la diferencia entre métodos y dentro de los métodos (Ecuaciones 2.44 y 2.45). Posteriormente, se computan los cuadrados medios del tratamiento y del error. Estos definen el efecto ponderado de cada fuente de variación (Ecuaciones 2.46 y 2.47). Por último, se evalúa el estadístico de la prueba (Ecuación 2.42) (Chandrakantha, 2014).

$$SC_T = \sum_{i=j}^4 \sum_{j=1}^4 Y_{ij}^2 - \frac{Y^2_{..}}{N} \quad (2.43)$$

$$SC_{TRAT} = \sum_{i=1}^4 \frac{Y_i^2}{4} - \frac{Y^2..}{N} \quad (2.44)$$

$$SC_E = SC_T - SC_{TRAT} \quad (2.45)$$

$$CM_{TRAT} = \frac{SC_{TRAT}}{k-1} \quad (2.46)$$

$$CM_E = \frac{SC_E}{N-k} \quad (2.47)$$

2.2.11.2. Prueba de Tukey

El método de Tukey es utilizado para comparar las diferencias entre las medias muestrales de un conjunto de n tratamientos (Gutierrez y Roman, 2009; Homack, 2001). Está basado en el cálculo de un valor crítico (T_α) el cual es usado para determinar las diferencias entre las medias de los tratamientos (Jorge Dagnino, 2014). El valor crítico está dado por la Ecuación 2.48.

$$T_\alpha = q_\alpha(k, N-k) \sqrt{\frac{CM_E}{n_i}} \quad (2.48)$$

Donde CM_E es el cuadrado medio del error, n es el número de observaciones de los tratamientos, k es el número de tratamientos, $N - K$ son los grados de libertad del error, α el nivel de significancia y $q_\alpha (k, N - k)$ son puntos porcentuales de la distribución del rango estudentizado (Williams y Abdi, 2014).

III . Hipótesis

Al definir un modelo de clasificación para detectar fallas en servidores utilizando análisis de componentes principales y descriptores estadísticos de primer orden extraídos de imágenes térmicas, se encuentra que existe una diferencia estadísticamente significativa entre la exactitud predictiva otorgada por los espacios de color RGB, HSV, CMY, HSI, CIE L*a*b y escala de grises.

IV . Objetivos

4.1. Objetivo general

Integrar en una metodología la aplicación del análisis de componentes principales y los descriptores estadísticos de primer orden obtenidos de los espacios de color RGB, HSV, CMY, HSI, CIE L*a*b y la escala de grises, para comparar la exactitud de los modelos predictivos de clasificación para detectar fallas en servidores.

4.2. Objetivos específicos

- Proveer una herramienta a metodologías que integren aprendizaje automático y procesamiento de imágenes para identificar la representación de color en la imagen que defina mejor las características de una aplicación en específico.
- Establecer las variables que definen las cinco condiciones de falla de un servidor determinadas por la suma acumulativa de eigenvalores que sea mayor al 80% de la varianza total.
- Contrastar la capacidad predictiva de los espacios de color RGB, HSV, CMY, HSI, CIE L*a*b y la escala de grises para determinar el que proporciona mayor exactitud en la detección de fallas en servidores.

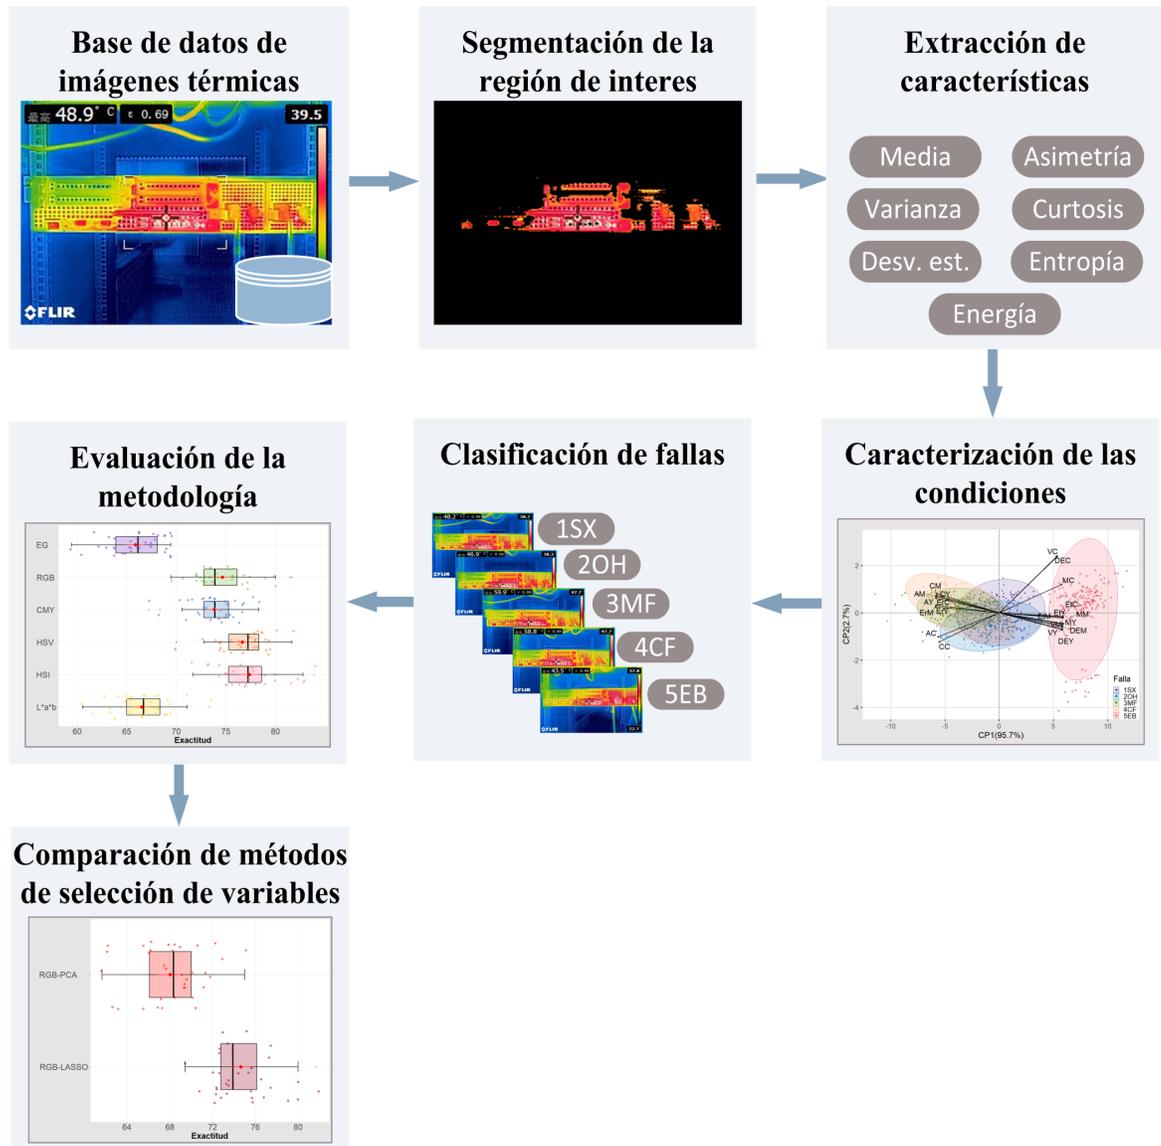
V . Metodología

En esta sección se describe la metodología propuesta para comparar el rendimiento de diferentes espacios de color y escala de grises, para identificar el que mejor mapea un conjunto de características (Espinoza-Del Angel y Femat-Díaz, 2022). El diagrama de flujo de la Figura 5.1 muestra las siete etapas principales de la metodología, base de datos de imágenes térmicas, segmentación de la región de interés, extracción de características, caracterización de las condiciones, clasificación de fallas, evaluación de la metodología y comparación de métodos de selección de variables. Después se describe el proceso de segmentación del área de interés. A partir de esta región se efectuó la extracción de los descriptores estadísticos de primer orden. Usando estos parámetros como variables de entrada, se caracterizaron cinco condiciones de estado de un servidor aplicando análisis de componentes principales. Utilizando el k-NN se llevó a cabo la clasificación automática de las fallas y se evaluó la eficiencia del modelo mediante una matriz de confusión. Posteriormente, se realizó una comparación estadística del rendimiento de los espacios de color y la escala de grises empleando ANOVA y la prueba de Tukey. Por último, se efectuó la comparación del ACP y la regresión logística múltiple penalizada.

5.1. Base de datos de imágenes térmicas

Las imágenes utilizadas en este estudio pertenecen a la base de datos publicada por Liu *et al.* (Liu *et al.*, 2017a). Esta es una colección de imágenes termográficas de un servidor marca DELL, modelo 720. Las fallas se relacionan con problemas en la ventilación y la distribución térmica del CPU. En total contiene cinco condiciones de falla, dos condiciones están relacionadas con el estado de carga del CPU, 60% y 100% (1SX y 2OH), y dos con el ventilador, el ventilador principal y el ventilador del CPU (3MF y 4CF); la última condición se refiere a un bloqueo de entrada en la ventilación (5EB). Las imágenes fueron capturadas

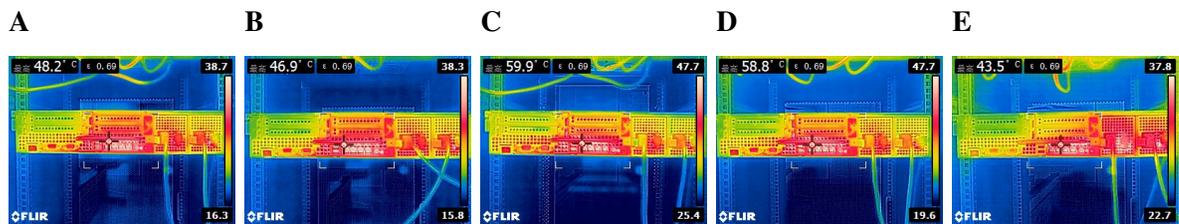
Figura 5.1
Diagrama de flujo de la metodología.



por una cámara FLIR E8 a una resolución de 320x240 píxeles y un factor de emisividad de 0.64. En este estudio se utilizó un total de 898 muestras, 179, 1SX; 180, 2OH; 179, 3MF; 180, 4CF; y 180 5EB. En la Figura 5.1 se visualiza una imagen muestra por cada condición de estado del servidor. La información a detalle de la cámara, servidor e información de las fallas se anexa en el Anexo A.

Figura 5.2

Imágenes muestra de la base de datos.



Nota. A: 1SX, B: 2OH, C: 3MF, D: 4CF, E: 5EB.

5.2. Segmentación de la región de interés

Basándose en las propiedades de la escala asignada por el software de la cámara termográfica, cada imagen en espacio de color HSV fue segmentada de manera preliminar con el método de segmentación de umbral. El algoritmo de segmentación consistió en la transformación de la imagen RGB a HSV, después se separaron cada una de las componentes de matiz (H), Saturación (S) y Valor (V). A partir de estas, se seleccionaron los valores de umbral alto y bajo para cada una de ellas. El rango de umbral para la componente H fue de 0.885 a 0.065, en S de 0 a 1, y en V de 0.630 a 1. Posteriormente, se realizó un cierre morfológico con un elemento estructural en forma de disco de radio 1 para rellenar los agujeros. La máscara resultante se utilizó para establecer el área de interés en las imágenes originales. El código de la segmentación puede visualizarse en el Anexo B, este fue realizado mediante el software de acceso libre Octave.

5.3. Extracción de características

De cada imagen segmentada, se obtuvo una imagen para cada canal de los modelos de color y su transformación a escala de grises. A partir de aquí se calcularon las características de media, varianza, desviación estándar, asimetría, energía y entropía para cada una de las condiciones del servidor (Akole y Kulkarni, 2016; Khamisan *et al.*, 2015; Taheri-Garavand *et al.*, 2015). Las ecuaciones utilizadas para obtener los descriptores estadísticos se encuentran descritas en el marco teórico dentro del apartado correspondiente a “Descriptores estadísticos

de primer orden” Ecuaciones 2.19 a 2.24. El código Octave para el cálculo de las características se encuentra dentro del Anexo C. Por imagen se obtuvo un total de 21 características para cada espacio de color y siete características para la escala de grises.

5.4. Caracterización de las condiciones

Utilizando los descriptores estadísticos como variables de entrada, se usó análisis de componentes principales para obtener el modelo que explicara el comportamiento de las condiciones del servidor. El primer paso para realizar el análisis fue la verificación de los supuestos estadísticos. Estos fueron verificados mediante las pruebas de Kaiser-Meyer-Olkin (KMO) y Bartlett. La adecuación del muestreo se evaluó examinando el coeficiente KMO. Una correlación por encima de 0.70 se consideró adecuada para analizar los datos extraídos. Una vez que esto se fue verificado, se llevó a cabo la prueba de esfericidad de Bartlett. Esta comprobó la existencia de multicolinealidad entre las variables usadas. En ambos análisis se utilizó un nivel de significancia de 0.05. Después de comprobar que los datos extraídos son útiles, se procedió a efectuar el ACP empleando los paquetes “stats” y “FactoRMine” del software Rstudio (Anexo D). Los componentes principales fueron seleccionados mediante el método de la varianza total, conservando aquellos que retienen un acumulado de la varianza de al menos un 80 %.

5.5. Clasificación de fallas

El algoritmo k vecinos más cercanos fue utilizado como clasificador de fallas y fue entrenado usando los componentes determinados por el análisis de componentes principales. Este proceso fue realizado empleando Rstudio, el código se muestra en el Anexo E. Las 898 muestras se dividieron aleatoriamente en dos conjuntos diferentes. Un 80 % se usó como datos de entrenamiento y un 20 % de prueba. La distancia entre datos fue determinada en función de la euclídea (Ver Ecuación 2.35). Posteriormente, se asignó una clase de falla al

punto de prueba según el valor de k vecinos, que fue definido en 27 (Ver Ecuación 2.34). Para evaluar la eficiencia del modelo predictivo, se obtuvo la métrica de exactitud. Esta fue calculada a partir de una matriz de confusión.

5.6. Evaluación de la metodología

Los datos de exactitud determinados por la matriz de confusión se analizaron mediante un análisis de varianza de una vía y la prueba posthoc de Tukey. Se calculó el tamaño muestral usando el análisis de potencia estadística. Para esto se fijó una potencia de 0.8, un tamaño del efecto de 0.25 y un nivel de significancia de 0.05. El resultado fue de 35. La normalidad de los residuos se evaluó realizando la prueba de Shapiro Wilks y la homogeneidad de varianzas se demostró mediante la prueba de Bartlett. Para todos los análisis estadísticos se utilizó un nivel de significancia de $p < 0.05$.

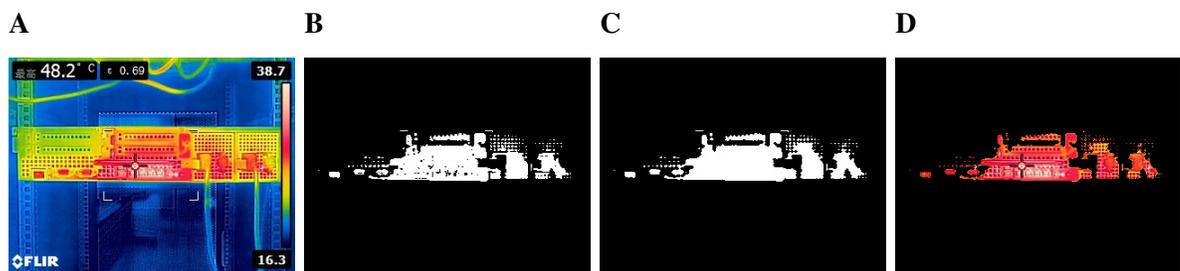
5.7. Comparación de métodos de selección de variables

Por último, se realizó la comparación del PCA y la regresión logística múltiple penalizada (LASSO). Como primer paso, se obtuvo el factor de inflación de la varianza (VIF, por sus siglas en inglés) para la evaluación del supuesto de multicolinealidad. Posteriormente, se realizó la selección del valor óptimo de regularización (λ) mediante el método de validación cruzada. Este procedimiento fue realizado mediante el software RStudio usando la librería “glmnet” (Friedman *et al.*, 2010). Finalmente, la clasificación fue realizada mediante las variables explicativas determinadas por el modelo LASSO y k-NN. Los métodos PCA y LASSO se compararon a partir de los datos de exactitud obtenidos.

VI. Resultados y discusión

Esta sección muestra los resultados de comparación entre los espacios de color y la escala de grises. Al aplicar el procedimiento descrito en la metodología, los resultados de segmentación del área con mayor temperatura se muestran en la Figura 6.1. En esta, la imagen térmica original se aprecia en la Figura 6.1A, la máscara binaria obtenida a partir de la segmentación en la Figura 6.1B, el resultado del filtrado morfológico en la Figura 6.1C y la extracción del área con mayor concentración de calor en la Figura 6.1D.

Figura 6.1
Segmentación del punto caliente en el servidor.



Nota. A: Imagen original, B: Mascara binaria, C: Filtrado morfológico, D: Imagen segmentada.

Considerando una imagen de muestra, la conversión a escala de grises y la separación por canal de los espacios de color se visualizan en el Cuadro 6.1. Para cada una de las 898 muestras se extrajeron los descriptores estadísticos por espacio de color. El cuadro 6.2 muestra como ejemplo la matriz de datos resultante para el espacio RGB. Esta contiene 898 filas con 179 observaciones para cada una de las condiciones 1SX y 3MF; y 180 para 2OH, 4CF y 5EB. El resultado de medición para cada descriptor estadístico se muestra por columna (21 características para los espacios RGB, CMY, HSV, HSI y CIE L*a*b y 7 para escala de grises).

A partir de las matrices resultantes, se realizó la verificación de los supuestos estadísticos del ACP. El Cuadro 6.3 contiene los resultados del cálculo del coeficiente Kaiser-

Cuadro 6.1

División de canales de los sistemas de color.

Sistema de color	EG	RGB	CMY	HSV	HSI	CIE L*a*b
Canal 1						
Canal 2						
Canal 3						

Nota. Canal 1, canal 2 y canal 3 corresponden a la bandas de cada espacio de color. Escala de grises (EG).

Meyer-Olkin (KMO) y prueba de esfericidad de Bartlett. En la prueba de Bartlett, todas las representaciones de color obtuvieron un p-valor significativo menor al nivel α de 0.05, esto comprueba la existencia de correlación entre descriptores estadísticos. Así mismo, el coeficiente KMO en todos los casos fue mayor a 0.7 por lo que las representaciones de color cumplen satisfactoriamente con el criterio de adecuación de muestreo. Ambas pruebas demostraron que los datos obtenidos en el estudio son adecuados para llevar a cabo el ACP.

Los resultados del ACP se resumen en las gráficas de la Figura 6.2 (los datos completos se encuentran en el Anexo F). Estas son una proyección del espacio bidimensional del ACP a partir de dos componentes principales. Los CP fueron seleccionados considerando la regla de conservación de la varianza total, reteniendo al menos el 80% de la información del conjunto de variables originales. Los títulos de los ejes vertical y horizontal muestran el porcentaje de varianza explicada por los componentes principales 1 y 2. La contribución de varianza acumulada del primero y segundo componente principal en todos fue mayor de 95%. Los CP 1 y 2 en la escala de grises explican el 99.8% de la varianza. Esta retiene mayor cantidad de información en sus dos primeras componentes en comparación con los espacios

Cuadro 6.2

Matriz de datos RGB.

Muestra	MR	VR	DER	AR	CR	ErR	EtR	...	CB	ErB	EtB
F7940	17.34	3727.56	61.05	3.31	9.15	0.85	0.10	...	26.76	0.86	0.11
F7941	19.04	4081.35	63.89	3.12	7.91	0.84	0.11	...	24.82	0.85	0.12
F7942	19.27	4127.17	64.24	3.09	7.74	0.84	0.11	...	25.64	0.85	0.12
⋮
F8391	21.21	4485.26	66.97	2.90	6.58	0.82	0.12	...	18.72	0.83	0.14
F8392	21.29	4497.88	67.07	2.89	6.55	0.82	0.12	...	18.64	0.83	0.14
F8393	21.72	4573.78	67.63	2.86	6.33	0.82	0.12	...	18.06	0.83	0.14

Nota. La inicial de los canales del espacio de color RGB fue añadida a cada descriptor estadístico. Media (M), varianza (V), desviación estándar (DE), asimetría (A), energía (Er) and entropía (Et).

Cuadro 6.3

Resultados de KMO y prueba de Bartlett para el análisis de ACP.

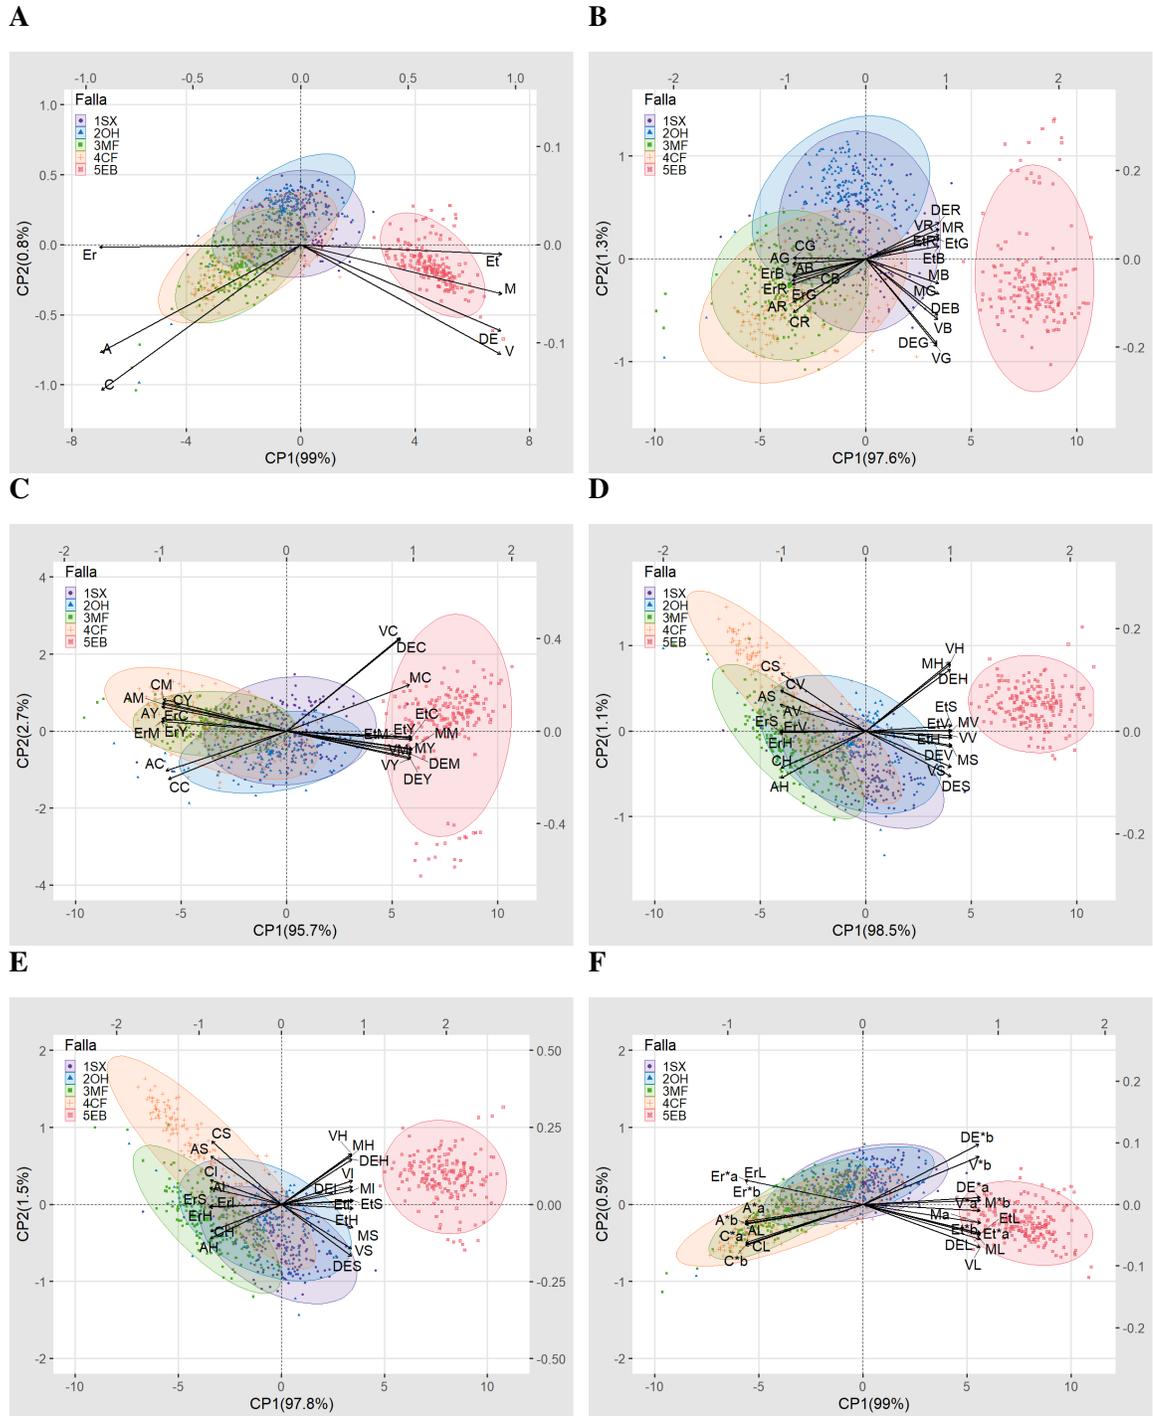
Prueba	EG	RGB	CMY	HSV	HSI	CIE L*a*b
KMO	0.74	0.89	0.87	0.87	0.89	0.88
Bartlett						
χ^2	40258.68	139256.7	137061.7	162190.7	154944.2	176991.3
gv	21	210	210	210	210	210
<i>p</i> – valor	0	0	0	0	0	0

Nota. Coeficiente Kaiser-Meyer-Olkin (KMO), chi-cuadrada (χ^2), grados de libertad (gv), escala de grises (EG).

de color RGB (98.9%), CMY (98.4%), HSV (99.6%), HSI (99.3%) y CIE L*a*b (99.5%). También se puede apreciar que el espacio CMY es el de mayor pérdida de información con un 98.3%.

Los vectores negros dentro de la gráfica son llamados vectores de cargas (en inglés, loadings). Estos representan los descriptores estadísticos, su longitud refleja el grado de contribución a los componentes principales y el ángulo entre ellos es su correlación. Los vectores que apuntan en direcciones iguales indican variables correlacionadas positivamente y los que

Figura 6.2
Gráfica PCA para los componentes 1 y 2.



Nota. A: escala de grises, B: RGB, C: CMY, D: HSV, E: HSI, F: CIE L*a*b. Media (M), varianza (V), desviación estándar (DE), asimetría (A), energía (Er) y entropía (Et).

tienen direcciones opuestas están correlacionados negativamente. Si presentan un ángulo de 90° indican una correlación baja o nula. Las coordenadas superior y derecha (eje de abscisas y ordenadas para los vectores de cargas CP1 y CP2) muestran el grado de contribución a los componentes principales. Estos van en un rango de -1 a 1. Las cargas cercanas a $|1|$ indican que la variable influye fuertemente en el componente principal. Las cercanas a 0 denotan una influencia débil. Un coeficiente superior a $|0,2|$ se considera significativo para definir un CP.

En todas las representaciones de color, las variables originales tienen una contribución mayor a $|0,98|$ en CP1. Así mismo para esta componente, la asimetría, curtosis y energía presentan una correlación alta negativa. El resto de las variables tienen una correlación alta positiva. En CP2, todos los espacios de color tienen una influencia débil. Los descriptores estadísticos en la escala de grises y el espacio CIE L^*a^*b tienen coeficientes cercanos a $|0,1|$. En RGB, la varianza y la desviación estándar del canal G son los que presentan mayor influencia en la CP2. En CMY únicamente los descriptores estadísticos de la banda C contribuyen al componente principal 2, a excepción de la asimetría, energía y entropía. En HSV y HSI solo un descriptor estadístico contribuye a la variabilidad de PC2, la varianza del canal H y la curtosis del canal S, respectivamente.

Los puntos en la gráfica son puntuaciones de los PC para cada muestra. Estos son agrupados en elipses de concentración, determinadas a un nivel de confianza del 95%. Las observaciones son agrupadas por falla de servidor. La elipse en violeta agrupa la condición 1SX; en azul, 2OH; en verde, 3MF; en naranja, 4CF; y en rojo, 5EB. Los individuos del mismo lado que una variable tienen una contribución alta en ella. En escala de grises, la condición 5EB se caracteriza por altos valores de media, varianza, desviación estándar y entropía. El modo de falla 3MF por altos valores de curtosis y energía; y 4CF por la asimetría y energía. Las condiciones 1SX y 2OH están algo en medio con individuos menos agrupados que cualquier grupo (Ver Figura 6.2A).

Al igual que escala de grises, en los espacios de color RGB, CMY, HSI, HSV y CIE L^*a^*b es posible apreciar el mismo patrón de contribución de las variables para cada una de las fallas. Además, se puede visualizar que tanto en los espacios de color RGB, CMY, CIE L^*a^*b , HSI y HSV; como en la escala de grises las condiciones 1SX, 2OH, 3MF y 4CF se superponen, mientras que la condición 5EB es la única que presenta una clara separación de las demás. Por este motivo, el clasificador k-NN no tuvo problemas al diferenciar esta condición. En todas las representaciones de color presento una sensibilidad y especificidad del 100%. Los resultados de exactitud del modelo predictivo se muestran en el Cuadro 6.4. Para cada una de las 35 muestras se consideró un nuevo conjunto de datos aleatorios.

Utilizando los datos del Cuadro 6.4 se aplicó un ANOVA de una vía para comparar estadísticamente la exactitud de los espacios de color y la escala de grises. Los resultados de las pruebas Shapiro-Wilks y Bartlett se muestran en el Cuadro 6.5. En la prueba de normalidad mediante Shapiro-Wilks el p-valor fue mayor que el nivel de significancia de 0.05. Por lo tanto, se confirma que los residuos del modelo siguen una distribución normal. El cumplimiento de homogeneidad de varianza entre tratamientos se determinó mediante la prueba de Bartlett. El p-valor de 0.786 sugiere que no hay evidencia de que existan variaciones estadísticamente significativas entre representaciones de color.

El análisis de varianza reveló que existe una diferencia significativa entre los modelos de color con un p-valor menor a 0.05 (Ver Cuadro 6.6). En la Figura 6.3A se muestra el diagrama de cajas del ANOVA para los espacios de color. En esta la distribución de las representaciones de color exhibe una distribución normal, ya que los valores atípicos son mínimos. Los bigotes de la caja representan los límites de las muestras de exactitud extraídas para cada grupo. La media se puede visualizar en el punto rojo, en escala de grises fue de 64.36%; en RGB, 68.03%; en CMY, 68.29%; en HSV, 72.56%; en HSI, 73.17%; y en CIE L^*a^*b , 59.44%. El modelo predictivo dado por las características del espacio de color CIE L^*a^*b fue el que obtuvo la menor exactitud, seguido de la escala de grises. El espacio HSI fue el de mayor exactitud.

Cuadro 6.4*Resultados de exactitud de los espacios de color para el método PCA+k-NN.*

Muestra	EG	RGB	CMY	HSV	HSI	CIE L*a*b
1	64.44	66.11	65.00	75.56	72.78	58.89
2	68.33	69.44	66.67	71.11	72.22	61.67
3	66.67	67.22	70.00	71.67	70.56	61.11
4	65.56	67.78	67.22	71.11	71.11	60.00
5	65.56	70.56	69.44	73.33	75.00	58.33
6	67.78	68.33	67.22	73.33	73.89	61.11
7	66.11	68.89	71.67	76.67	74.44	61.11
8	64.44	61.67	68.33	72.22	71.67	64.44
9	59.44	63.33	65.00	70.00	71.11	57.22
10	59.44	62.22	64.44	66.11	66.67	54.44
11	56.67	62.22	65.00	72.22	73.89	56.11
12	64.44	71.11	70.56	72.78	75.00	60.00
13	66.67	68.33	67.22	70.56	76.11	59.44
14	63.33	66.11	65.56	71.67	70.00	57.78
15	62.78	65.56	66.67	71.67	70.00	57.22
16	65.56	67.78	71.67	73.33	75.00	61.11
17	62.22	66.67	67.22	68.89	72.22	56.67
18	66.67	69.44	71.11	77.22	77.78	61.67
19	64.44	75.00	72.22	71.67	72.78	62.22
20	58.89	65.56	60.00	73.89	71.11	59.44
21	63.33	67.22	67.22	76.11	78.89	63.33
22	64.44	69.44	73.89	70.00	73.33	60.56
23	60.56	62.78	61.67	67.22	68.89	53.89
24	65.56	71.67	71.11	77.22	78.33	62.78
25	63.33	68.89	66.67	70.00	75.56	57.22
26	65.00	67.22	70.56	74.44	70.56	56.11
27	62.78	66.11	68.89	72.22	73.33	57.78
28	65.00	72.78	67.22	71.11	72.22	55.56
29	67.22	70.56	73.33	72.78	73.33	61.11
30	65.00	70.00	64.44	72.22	70.00	57.22
31	68.33	71.11	73.89	72.78	72.78	60.00
32	67.78	72.22	71.11	73.33	74.44	61.11
33	66.67	69.44	65.56	72.78	70.56	56.67
34	63.33	68.33	72.78	79.44	81.11	66.11
35	65.00	70.00	69.44	72.78	74.44	61.11
μ	64.36	68.03	68.29	72.56	73.17	59.44

Nota. Los datos están en porcentaje (%). Promedio (μ), escala de grises (EG).

Cuadro 6.5

Resultados de las pruebas Shapiro-Wilks y Bartlett para la verificación de supuestos del ANOVA para el método PCA+k-NN.

Prueba	Estadístico W/χ^2	gv	p-valor
Shapiro-Wilks	0.9958	-	0.835
Bartlett	2.4365	5	0.786

Nota. Chi-cuadrada (χ^2), grados de libertad (gv)

Cuadro 6.6

Resultados del ANOVA en PCA+k-NN.

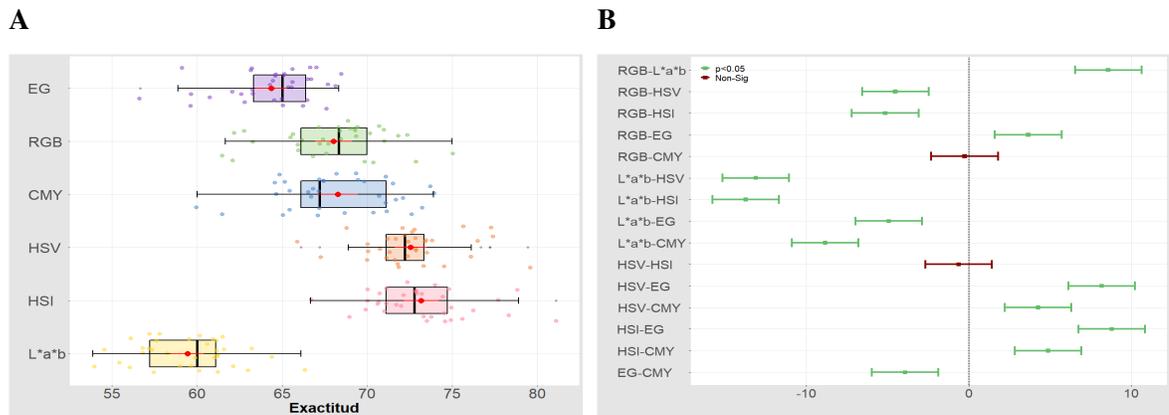
Fuente	gv	Suma de cuadrados	Cuadrado medio	Estadístico F	p-valor
Modelo	5	4664	932.8	104.8	<2e-16
Error	204	1816	8.9		

Nota. Grados de libertad (gv)

Los resultados de la prueba Tukey para los modelos de color se pueden visualizar en la Figura 6.3B. En el gráfico, el eje x representa la diferencia de medias por pares. Las líneas extendidas muestran los intervalos de confianza del 95%. Los que cruzan el 0 (línea punteada) indican que no hay diferencia estadísticamente significativa entre los pares de medias (Ver Figura 6.3B líneas rojas). El contraste entre los espacios RGB y CMY dio como resultado una diferencia media de -0.25 con un p-valor = 0.99, lo que indica que no existe una diferencia estadística entre ellos. También la comparación entre los espacios HSI y HSV reveló que no hay una desigualdad de medias (p-valor = 0.95).

Figura 6.3

Resultados de la comparación estadística del PCA+k-NN



Nota. A: Gráfica de caja del ANOVA para las representaciones de color, B: Gráfico de comparación por pares de medias de Tukey.

Posteriormente, se realizó la comparación de los modelos de predicción PCA+k-NN y LASSO+k-NN. Como primer paso, se obtuvo el factor de inflación de la varianza que es usado para detectar la multicolinealidad entre los momentos estadísticos del modelo de regresión.

Los cuadros del Anexo G muestran los resultados del VIF calculados utilizando el método de uno-vs-todos (OvR, por sus siglas en inglés). Los resultados sugieren que existe presencia de multicolinealidad grave, ya que el valor VIF para cada representación de color es superior a 10. Esto mismo se corrobora con la prueba de Bartlett realizada como supuesto para el ACP (Ver Cuadro 6.3), donde se había comprobado con anterioridad la existencia de correlación entre las variables del conjunto de dato. Por este motivo, una regresión logística múltiple no puede ser usada de manera convencional; debido a que la presencia de multicolinealidad incrementa la varianza de los coeficientes de regresión (β) provocando su inestabilidad. Esto reduce el poder del modelo para identificar las variables estadísticamente significativas. Para lidiar con este problema se realizó una regresión logística múltiple penalizada mediante el método LASSO (del inglés, least absolute shrinkage and selection operator).

Los resultados de la regresión LASSO se visualizan en el Cuadro 6.7. El valor de lambda (λ) del modelo identifica el valor óptimo que minimiza la tasa de error de predicción. Para los modelos en escala de grises, RGB y CMY fue de 0.01; en HSI y CIE L*a*b, 0.009; y en HSV, 0.007. En todas las representaciones de color se obtuvo un R^2 mayor al 99%, por lo tanto, un alto porcentaje de la variación en la respuesta puede ser explicado por los momentos estadísticos utilizados en el estudio. Así mismo, el valor de error cuadrático medio (MSE, por sus siglas en inglés) en todos los espacios de color fue menor a 10, lo que nos indica que existe un error bajo de predicción. El modelo de regresión para escala de grises solo contiene 4 variables explicativas de las 6 variables iniciales. Para los espacios de color de las 21 variables iniciales en RGB, HSV y CIE L*a*b se determinaron 6 variables explicativas; en HSI, 7; y en CMY, 8.

Cuadro 6.7

Resultado LASSO para las representaciones de color

Representación de color	Lambda	R^2	MSE	No. variables MF
Escala de grises	0.01014	99.98	9.90	4
RGB	0.01034	99.97	9.92	6
CMY	0.01222	99.97	9.91	8
HSV	0.00785	99.97	9.92	6
HSI	0.00946	99.97	9.92	7
CIE L*a*b	0.00924	99.98	9.91	6

Nota. Los datos de R^2 están en porcentaje (%), modelo final (MF), error cuadrático medio (MSE).

Las Ecuaciones 6.1 a 6.5 muestran los modelos matemáticos finales de las cinco fallas del servidor determinados por la regresión LASSO en escala de grises. Las variables de media, varianza y entropía se descartaron, ya que obtuvieron un valor β igual a 0. En esta representación de color, las variables más significativas en las condiciones cinco del servidor son la energía (Er), desviación estándar (DE), curtosis (C) y asimetría (A). De estas la variable con la β de mayor peso en todas las condiciones fue la energía. El tamaño de β para la desviación estándar, curtosis y asimetría varía dependiendo la condición del servidor.

$$y(1SX) = 39,12 + (-39,01Er) + (-0,09DE) + (-0,09C) + (-0,03A) \quad (6.1)$$

$$y(2OH) = 134,24 + (-88,57Er) + (-1,47DE) + (-0,35C) + (-0,27A) \quad (6.2)$$

$$y(3MF) = -61,80 + (-52,97Er) + (0,77C) + (0,42A) + (0,15DE) \quad (6.3)$$

$$y(4CF) = -182,08 + (193,68Er) + (0,48DE) + (0,12A) + (0,50E) \quad (6.4)$$

$$y(5EB) = 70,51 + (-119,08Er) + (0,93DE) + (-0,37C) + (-0,24A) \quad (6.5)$$

Para el espacio RGB las variables más significativas son la desviación estándar (*DE*) y la curtosis (*C*) de los canales R, G y B. Los coeficientes beta de cada modelo de regresión en el espacio RGB son mostrados en las Ecuaciones 6.6 a 6.10.

$$y(1SX) = 14,79 + (-0,67CR) + (0,24DEG) + (0,12DER) + (0,02CB) + (-0,02CG) \quad (6.6)$$

$$y(2OH) = 23,16 + (-1,89DEG) + (-0,59CR) + (0,37DER) + (0,17CG) \quad (6.7)$$

$$y(3MF) = 15,56 + (1,25DEG) + (-0,31DER) + (0,21CB) + (0,17CR) + (0,12CG) \quad (6.8)$$

$$y(4CF) = -8,03 + (1,62CR) + (-0,40DER) + (-0,26DEG) + (-0,18CG) \\ + (-0,13CB) \quad (6.9)$$

$$y(5EB) = -45,47 + (0,66DEG) + (-0,53CR) + (0,22DER) + (-0,11CB) \\ + (-0,09CG) \quad (6.10)$$

En CMY los descriptores estadísticos de mayor importancia en las condiciones del servidor son la desviación estándar (*DE*) de los canales C, M e Y; la asimetría (*A*) de C y

M; la entropía (Et) de Y; la energía (E) del canal C; y la curtosis (C) del canal M, como se aprecia en las Ecuaciones 6.11 a 6.15.

$$y(1SX) = -40,46 + (-11,79EtY) + (4,34ErC) + (1,55DEC) + (0,87AM) + (0,42DEY) \\ + (0,14AC) + (-0,12DEM) + (0,09CM) \quad (6.11)$$

$$y(2OH) = 29,32 + (7,49ErC) + (0,50DEM) + (-0,32DEY) + (0,30AC) + (-0,22CM) \\ + (-9,28EtY) + (-3,06DEC) + (-1,06AM) \quad (6.12)$$

$$y(3MF) = -29,36 + (-17,85EtY) + (6,02AM) + (3,57ErC) + (-0,83AC) + (0,81CM) \\ + (-0,78DEC) + (0,58DEY) + (-0,30DEM) \quad (6.13)$$

$$y(4CF) = 68,48 + (17,02EtY) + (-6,91ErC) + (-2,51AM) + (1,57DEC) + (1,51AC) \\ + (-1,13DEY) + (-0,53DEM) + (-0,29CM) \quad (6.14)$$

$$y(5EB) = -27,96 + (21,90EtY) + (-8,50ErC) + (-3,33AM) + (-1,12AC) + (0,73DEC) \\ + (0,46DEM) + (0,44DEY) + (-0,39CM) \quad (6.15)$$

En el espacio HSV, la desviación estándar (DE) de H, S y V; y la varianza (V), la entropía (Et), y curtosis (C) del canal H son los que tienen mayor influencia en las condiciones del servidor (ver Ecuaciones 6.16 a 6.20).

$$y(1SX) = -38,55 + (202,87DES) + (-77,22VH) + (31,98EtH) + (-30,56DEH) \\ + (-6,92DEV) + (0,23CH) \quad (6.16)$$

$$y(2OH) = 3,81 + (-205,83EtH) + (69,19VH) + (45,89DES) + (28,15DEH) \\ + 14,04DEV - 0,12CH \quad (6.17)$$

$$y(3MF) = -0,48 + (-125,16VH) + (76,21DES) + (-61,92DEV) + (-55,30DEH) \\ + (12,43EtH) + (0,62CH) \quad (6.18)$$

$$y(4CF) = 82,46 + (-448,53DES) + (72,58EtH) + (36,51VH) + (31,15DEV) \\ + (19,17DEH) + (-0,38CH) \quad (6.19)$$

$$y(5EB) = -47,24 + (123,57DES) + (96,68VH) + (88,84EtH) + (38,53DEH) \\ + (23,65DEV) + (-0,34CH) \quad (6.20)$$

Como se aprecia en las Ecuaciones 6.21 a 6.25, las cuales contienen las variables significativas para cada falla del servidor en el espacio HSI, los momentos de mayor importancia son la desviación estándar (*DE*) de los canales H, S e I; la varianza (*V*) de H; la asimetría (*A*) de S, y la curtosis (*C*) de H e I.

$$y1SX = -30,58 + (228,77DES) + (-40,02VH) + (-37,51DEH) + (-6,32DEI) \\ + (-0,25AS) + (0,13CH) \quad (6.21)$$

$$y(2OH) = 53,82 + (-189,65DEI) + (-116,71DES) + (44,29DEH) + (43,54VH) \\ + (-2,76AS) + (-0,16CH) + (-0,06CI) \quad (6.22)$$

$$y(3MF) = -22,41 + (190,03DES) + (-106,03DEI) + (-76,16DEH) + (-70,40VH) \\ + (2,20AS) + (0,44CH) + (0,24CI) \quad (6.23)$$

$$y(4CF) = 48,17 + (-449,99DES) + (174,77DEI) + (16,93DEH) + (12,95VH) \\ + (1,77AS) + (-0,18CH) + (-0,09CI) \quad (6.24)$$

$$y(5EB) = -49,00 + (147,89DES) + (127,24DEI) + (53,93VH) + (52,45DEH) \\ + (-0,96AS) + (-0,24CH) + (-0,09CI) \quad (6.25)$$

En el espacio CIE L^*a^*b el modelo de regresión LASSO determinó que los descriptores estadísticos que influyen principalmente en las cinco fallas del servidor son, la des-

viación estándar (DE) de L , $*a$ y $*b$; la varianza (V) de L y $*a$; y la curtosis (C) del canal L (ver Ecuaciones 6.26 a 6.30).

$$y(1SX) = -19,26 + (130,59DE * b) + (-52,48VL) + (-15,38DEL) + (-4,39DE * a) \\ + (-1,84V * a) + (0,11CL) \quad (6.26)$$

$$y(2OH) = 11,61 + (-360,93VL) + (197,28DE * a) + (-153,66DEL) + (-107,74DE * b) \\ + (22,26Va) + (-0,16CL) \quad (6.27)$$

$$y(3MF) = 7,38 + (-147,34DE * a) + (99,87DE * b) + (-31,25VL) + (-18,06V * a) \\ + (-4,30DEL) + (0,85CL) \quad (6.28)$$

$$y(4CF) = 70,80 + (-209,61DE * b) + (-188,33DE * a) + (175,82VL) + (71,06DEL) \\ + (-19,08V * a) + (-0,38CL) \quad (6.29)$$

$$y(5EB) = -70,53 + (268,83VL) + (142,77DE * a) + (102,28DEL) + (86,89DE * b) \\ + (16,73V * a) + (-0,42CL) \quad (6.30)$$

Para realizar la clasificación de las condiciones del servidor, se utilizaron las variables explicativas determinadas por el modelo de regresión LASSO. El Cuadro 6.8 contiene los resultados de exactitud del clasificador k-NN. A partir de estos datos se realizó el ANOVA de una vía para la comparación estadística del parámetro de exactitud. Las pruebas de Shapiro-Wilks y Bartlett para la verificación de supuestos del ANOVA se visualizan en el Cuadro 6.9. La prueba de Shapiro-Wilks con un p-valor mayor al nivel de significancia de 0.05 sugiere que los residuos del modelo están normalmente distribuidos. La prueba de Bartlett, con un p-valor de 0.9479 determinó que no existe evidencia que haya homocedasticidad entre observaciones. Al comparar las medias de exactitud de los espacios de color, se demostró que existe una diferencia significativa entre ellas (Ver Cuadro 6.10).

En la Figura 6.4A se observa el diagrama de cajas de la comparación de las medias. La media para escala de grises fue de 65.87 %; en RGB, 74.64 %; en CMY, 73.83 %; en HSV, 76.67 %; en HSI, 77.38 %; y en CIE L*a*b, 66.49 %. La escala de grises fue el de peor desempeño, mientras que el espacio HSI presentó un mayor rendimiento con una exactitud con 77.38 %. Los resultados de la prueba Tukey para los modelos de color se pueden visualizar en la Figura 6.4B. Al igual que el modelo de clasificación PCA+k-NN, se determinó que no existe una desigualdad estadística entre los espacios RGB y CMY (diferencia media de 0.81 con un p-valor = 0.80); y HSI y HSV (diferencia media de -0.71 con un p-valor = 0.87).

Por último, la comparación del parámetro de exactitud de los modelos de predicción PCA+k-NN y LASSO+k-NN son visualizados en la Figura 6.5. En todas las representaciones de color existe una diferencia de exactitud, ya que no se visualiza una superposición entre cajas. También es posible apreciar que el modelo de clasificación LASSO+k-NN presenta menor dispersión en los datos para todas las representaciones de color. La diferencia de exactitud entre los modelos de clasificación PCA+k-NN y LASSO+k-NN para escala de grises fue de 1.51 %; en RGB, 6.61 %; en CMY, 5.54 %; en CIE L*a*b, 7.05 %; y en HSV y HSI la diferencia fue similar con un 4.11 % y 4.21 %, respectivamente. La representación de color que genera menor diferencia de exactitud en la clasificación utilizando distintos métodos de selección de características es la escala de grises. El CIE L*a*b y el RGB son los que presentan la mayor diferencia. En todos los casos la exactitud otorgada por el modelo de clasificación predictivo LASSO+k-NN fue superior.

Cuadro 6.8*Resultados de exactitud de los espacios de color para el método LASSO+k-NN.*

Muestra	EG	RGB	CMY	HSV	HSI	CIE L*a*b
1	68.89	76.67	72.22	80.00	77.22	65.56
2	65.56	75.56	75.56	81.67	78.33	71.11
3	63.33	73.33	76.67	75.56	76.11	66.67
4	69.44	75.56	72.78	77.78	78.33	73.33
5	66.11	80.00	73.89	78.89	82.78	68.89
6	66.11	72.78	72.22	75.56	77.22	67.78
7	68.89	81.67	77.78	78.89	83.89	65.56
8	62.78	73.33	75.00	72.78	76.67	60.56
9	63.89	72.22	72.78	74.44	73.33	65.56
10	67.78	77.22	76.67	78.33	77.78	69.44
11	66.11	73.89	75.56	77.78	78.89	66.67
12	65.56	73.89	73.33	76.67	74.44	63.89
13	69.44	77.22	76.67	79.44	80.00	68.89
14	62.22	72.22	71.11	76.67	75.00	64.44
15	66.67	72.22	74.44	77.22	75.00	66.11
16	67.78	75.56	75.00	77.78	78.89	66.67
17	63.89	72.22	68.33	70.00	75.56	63.33
18	64.44	72.78	71.67	76.11	77.22	67.22
19	59.44	69.44	70.56	70.00	71.67	62.78
20	60.56	72.78	73.89	74.44	73.33	66.67
21	66.11	73.33	73.33	75.00	75.00	68.33
22	68.89	75.56	75.00	76.67	76.67	69.44
23	67.22	73.33	72.78	74.44	75.56	65.00
24	66.11	80.00	73.89	79.44	81.67	68.89
25	68.89	75.56	76.11	77.22	82.22	67.22
26	65.00	77.22	67.22	78.33	76.11	61.67
27	67.22	76.67	74.44	78.89	80.00	63.89
28	69.44	75.00	76.11	76.11	77.78	66.67
29	63.89	72.22	75.00	79.44	76.67	63.33
30	68.33	78.89	78.33	78.33	82.78	68.89
31	65.00	72.78	71.11	74.44	77.22	66.67
32	65.56	73.33	72.78	76.11	77.78	68.33
33	61.67	74.44	74.44	77.22	77.78	65.00
34	69.44	72.78	73.33	77.78	74.44	67.78
35	63.89	70.56	73.89	73.89	75.00	65.00
μ	65.87	74.64	73.83	76.67	77.38	66.49

Nota. Los datos están en porcentaje (%). Promedio (μ), escala de grises (EG).

Cuadro 6.9

Resultados de las pruebas Shapiro-Wilks y Bartlett para la verificación de supuestos del ANOVA para el método LASSO+k-NN.

Prueba	Estadístico W/χ^2	gv	p-valor
Shapiro-Wilks	0.99288	-	0.4063
Bartlett	1.1683	5	0.9479

Nota. Chi-cuadrada (χ^2), grados de libertad (gv)

Cuadro 6.10

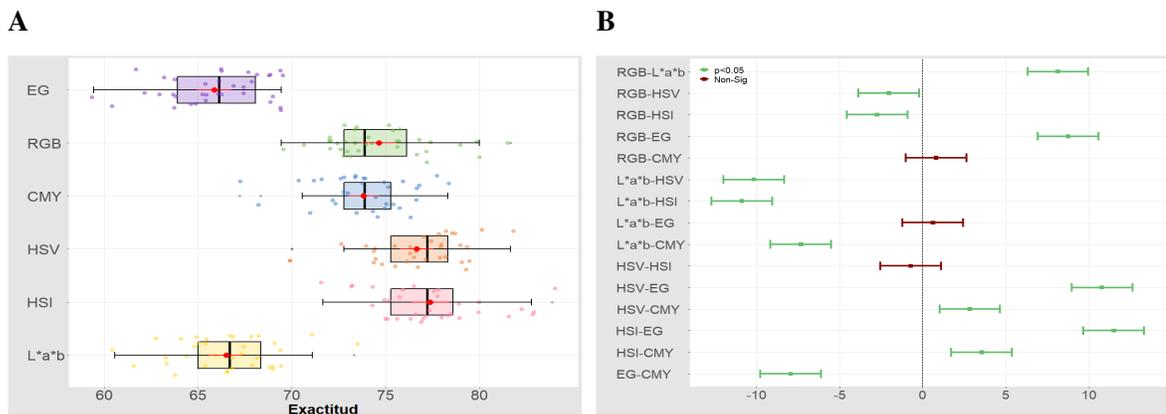
Resultados del ANOVA en LASSO+k-NN.

Fuente	gv	Suma de cuadrados	Cuadrado medio	Estadístico F	p-valor
Modelo	5	4463	892.5	126.3	<2e-16
Error	204	1442	7.1		

Nota. Grados de libertad (gv)

Figura 6.4

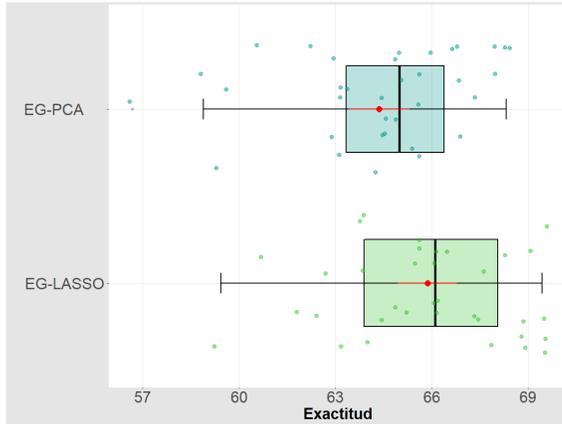
Resultados de la comparación estadística



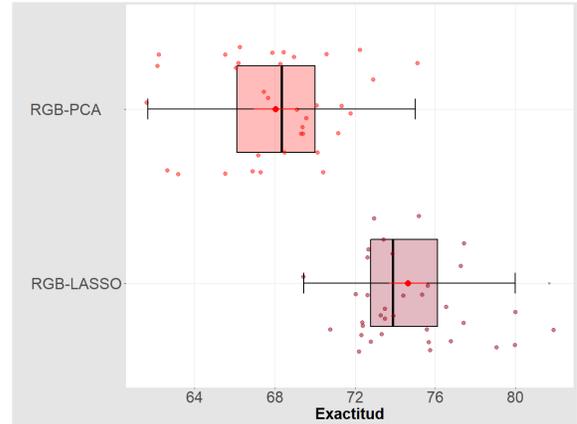
Nota. A: Gráfica de caja del ANOVA para las representaciones de color, B: Gráfico de comparación por pares de medias de Tukey.

Figura 6.5
Precisión del modelo PCA vs LASSO.

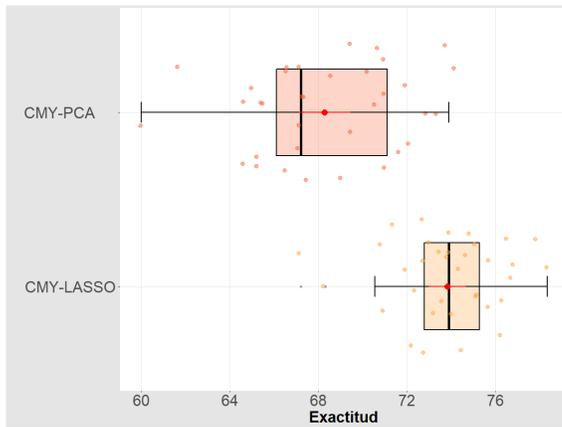
A Escala de grises



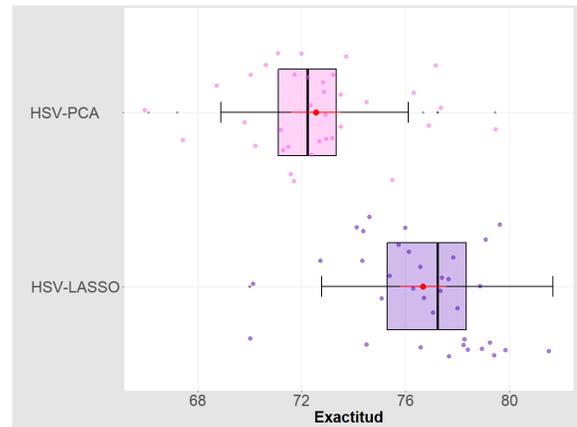
B RGB



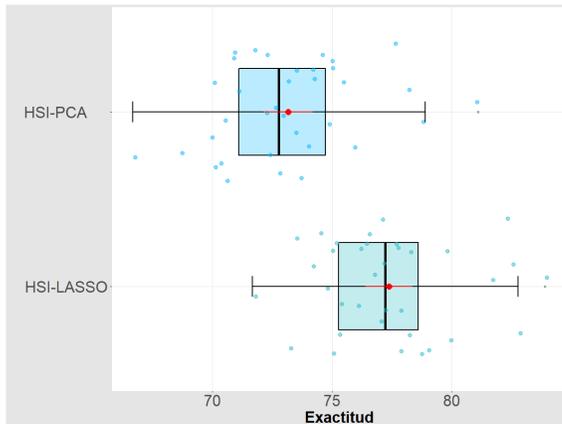
C CMY



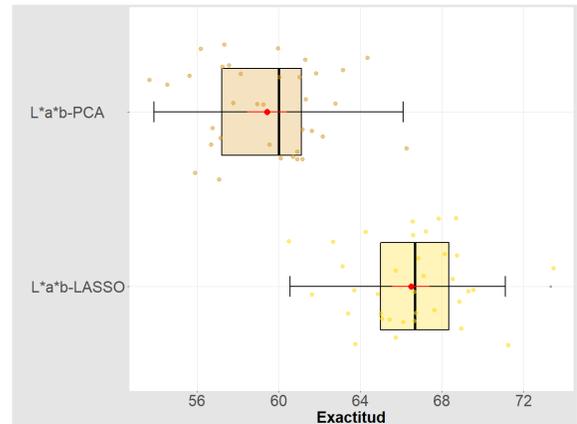
D HSV



E HSI



F CIE L*a*b



Nota. Escala de grises (EG).

VII . Conclusión

Del análisis comparativo se puede observar que la representación del color de la imagen térmica y los datos contenidos en ella pueden influir en el modelo predictivo de clasificación de fallas en una máquina o equipo. Comúnmente la escala de grises suele ser la representación del color más utilizada para la obtención de características de la imagen térmica debido a su sencillez de uso. A pesar de esto, su utilización puede disminuir drásticamente la exactitud de un modelo de predicción. La mejor forma de caracterizar las fallas de un servidor es mediante las características proporcionadas por el espacio HSI o HSV. Además, del estudio realizado, es posible concluir que existe una diferencia considerable entre un método de reducción de dimensionalidad como lo es el PCA y la selección de características por regresión LASSO. El sistema de detección de fallas por regresión LASSO obtiene mayor exactitud al caracterizar y clasificar fallas.

En conclusión, el uso de un espacio de color en el procesamiento de imágenes siempre debe estar justificado, debido a que cada modelo considera diferentes parámetros para la representación única de un tono. Como esta representación varía de un modelo a otro, la elección de un espacio de color se vuelve relevante para la caracterización de una clase o condición. En este sentido, al realizar un sistema de detección de fallas primero se debe seleccionar un modelo de color para obtener las características apropiadas para una aplicación específica con la finalidad de proporcionar información en profundidad.

La presente metodología ha proporcionado información relevante sobre como los espacios de color pueden influir en la caracterización y clasificación fallas. El uso de este método no queda limitado solo a la detección de fallas de dispositivos electrónicos, mecánicos o eléctricos. Esta puede ser utilizada en las distintas aplicaciones que usan aprendizaje automático y procesamiento de imágenes. Algunos ejemplos son, aplicaciones médicas donde usan imágenes para diferenciar o diagnosticar enfermedades; identificar objetos en imágenes satelitales; detectar y clasificar enfermedades o plagas en plantas; reconocer y distinguir entre enfermedades de animales; etc.

Bibliografía

- Abdi, H. y Williams, L. J. (2010). Principal component analysis. *Wiley Interdisciplinary Reviews: Computational Statistics*, 2(4):433–459.
- 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*, 1:1–6.
- Ahmed, M. M., Huda, A., e Isa, N. A. M. (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.
- Akole, S. S. y Kulkarni, V. B. (2016). Thermal Analysis of Active Electronic Component with Thermal Imaging. *ACM International Conference Proceeding Series*, 04-05-Marc(D):1–6.
- 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*, 104:103–140.
- Al-Obaidy, F. (2016). *IC Testing Using Thermal Image Based on Intelligent Classification Methods*. Tesis doctoral, Ryerson University.
- Al-Obaidy, F., Yazdani, F., y Mohammadi, F. A. (2017). Fault detection using thermal image based on soft computing methods : Comparative study. *Microelectronics Reliability*, 71:56–64.
- 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.
- 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.

- Altaf, S., Mehmood, M. S., y Soomro, M. W. (2019). Advancement of Fault Diagnosis and Detection Process in Industrial Machine Environment. *Journal of Engineering Sciences*, 6(2):d1–d8.
- 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*, pp. 261–266.
- Arellano, M. Á. y Morales, L. (2015). Electrical applications of infrared thermography : A review. *CONGRESO INTERNACIONAL DE INGENIERIA*, 11:2–5.
- Arizton (2021). Data Center Market in Latin America - Industry Outlook and Forecast 2021-2026.
- 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)*, pp. 1–6.
- 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.
- Bagavathiappan, S., Saravanan, T., George, N. P., Philip, J., Jayakumar, T., y Raj, B. (2008). Condition monitoring of exhaust system blowers using infrared thermography. *Insight: Non-Destructive Testing and Condition Monitoring*, 50(9):512–515.
- Batta, M. (2020). Machine Learning Algorithms: A Review. *International Journal of Science and Research (IJSR)*, 9(1):1174–1179.
- Bijalwan, V., Kumar, V., Kumari, P., y Pascual, J. (2014). KNN based machine learning approach for text and document mining. *International Journal of Database Theory and Application*, 7(1):61–70.
- Borja-Robalino, R., Monleón-Getino, A., y Rodellar, J. (2020). Estandarización de métricas de rendimiento para clasificadores Machine y Deep Learning. *Iberian Journal of Information Systems and Technologies*, 30(06):172–184.
- Cai, J., Luo, J., Wang, S., y Yang, S. (2018). Feature selection in machine learning: A new

- perspective. *Neurocomputing*, 300:70–79.
- Chaki, J. y Dey, N. (2020). *Image Color Feature Extraction Techniques*. Springer Singapore.
- Chandrakantha, L. (2014). Learning ANOVA concepts using simulation. *Proceedings of the 2014 Zone 1 Conference of the American Society for Engineering Education - .Engineering Education: Industry Involvement and Interdisciplinary Trends*”, ASEE Zone 1 2014.
- 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.
- 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.
- Chen, R. C., Dewi, C., Huang, S. W., y Caraka, R. E. (2020). Selecting critical features for data classification based on machine learning methods. *Journal of Big Data*, 7(1).
- Chomboon, K., Chujai, P., Teerarassammee, P., Kerdprasop, K., y Kerdprasop, N. (2015). An Empirical Study of Distance Metrics for k-Nearest Neighbor Algorithm. En *Proceedings of the 3rd International Conference on Industrial Application Engineering 2015*, pp. 280–285.
- 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.
- Choudhary, A., Shimi, S., y Akula, A. (2018). Bearing Fault Diagnosis of Induction Motor Using Thermal Imaging. En *2018 International Conference on Computing, Power and Communication Technologies (GUCON)*, pp. 950–955. IEEE.
- Cruz-Albarran, I. A., Benitez-Rangel, J. P., Osornio-Rios, R. A., Dominguez-Trejo, B., Rodriguez-Medina, D. A., y Morales-Hernandez, L. A. (2019). A new approach to obtain a colour palette in thermographic images. *Quantitative InfraRed Thermography Journal*, 16(1):35–54.
- Delloite (2019). Tendencias de industrias. *Delloite*.

- Diez, D. M., Barr, C. D., y Cetinkaya, M. (2010). OpenIntro : Statistics Preliminary Edition. *Public Health*, p. 266.
- Dong, Z. y Chen, L. (2019). Image registration in PCB Fault Detection Based on Infrared Thermal Imaging. *2019 Chinese Control Conference (CCC)*, pp. 4819–4823.
- 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.
- Duarte, A., Carrão, L., Espanha, M., Viana, T., Freitas, D., Bárto, P., Faria, P., y Almeida, H. (2014). Segmentation Algorithms for Thermal Images. *Procedia Technology*, 16:1560–1569.
- Dutta, T., Santra, D., Peng-Lim, C., Sil, J., y Chottopadhyay, P. (2019). *Statistical Feature Analysis of Thermal Images from Electrical Equipment*. Springer Singapore.
- Dutta, T., Sil, J., y Chottopadhyay, P. (2016). Condition monitoring of electrical equipment using thermal image processing. En *2016 IEEE First International Conference on Control, Measurement and Instrumentation (CMI)*, pp. 311–315. IEEE.
- Dwivedi, S. K., Vishwakarma, M., y Soni, P. A. (2018). Advances and Researches on Non Destructive Testing: A Review. *Materials Today: Proceedings*, 5(2):3690–3698.
- 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.
- Espinoza-del Angel, C. y Femat-Díaz, A. (2021). Termografía infrarroja pasiva aplicada a sistemas de detección de fallas: Una revisión. *Digital Ciencia@UAQRO*, 14(2):28–40.
- Espinoza-Del Angel, C. y Femat-Díaz, A. (2022). Comparison of accuracy of color spaces in cell features classification in images of leukemia types ALL and MM. *Mexican Journal of Biomedical Engineering*, 43(2):1–11.
- FLIR Systems Inc. (2011). Thermal imaging guidebook for industrial applications. *FLIR Systems*, p. 48.
- FLIR Systems Inc. (2018). How far can you go? Technical report, FLIR Systems Inc.
- Freund, R. J., Wilson, W. J., y Sa, P. (2006). *Regression Analysis*. Academic Press, 2nd edición.
- Friedman, J., Hastie, T., y Tibshirani, R. (2010). Regularization Paths for Generalized Linear

- Models via Coordinate Descent. *Journal of Statistical Software*, 33(1):1–22.
- Gallardo-saavedra, S., Hernández-callejo, L., y Duque-pérez, Ó. (2019). Analysis and characterization of PV module defects by thermographic inspection. *Revista Facultad de Ingeniería Universidad de Antioquia*, 93:92–104.
- García, S., Luengo, J., y Herrera, F. (2015). Feature selection. *Intelligent Systems Reference Library*, 72(6):163–193.
- Ghojogh, B., Samad, M. N., Mashhadi, S. A., Kapoor, T., Ali, W., Karray, F., y Crowley, M. (2019). Feature selection and feature extraction in pattern analysis: A literature review. *arXiv*.
- Glowacz, A. y Glowacz, Z. (2017). Diagnosis of the three-phase induction motor using thermal imaging. *Infrared Physics and Technology*, 81:7–16.
- Glowacz, A. A., Glowacz, A. 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.
- Gonzalez, R. C. y Woods, R. E. (2002). *Digital Image Processing (2nd Edition)*. Prentice-Hall, Division of Simon and Schuster One Lake Street Upper Saddle River, NJ United States, 2 edición.
- Gupta, A., Sharma, A., y Goel, A. (2017). Review of Regression Analysis Models. *International Journal of Engineering Research & Technology (IJERT)*, 6(8):1–5.
- Gutierrez, H. y Roman, S. (2009). *Control Estadístico de Calidad y Seis Sigma*. McGraw-Hill, 2nd edición.
- Gutierrez Pulido, H. y De la Vara Salazar, R. (2008). *Analisis y diseño de experimentos*, volumen 2. McGraw-Hill/In.
- Gyorok, G. y Beszedes, B. (2019). Using thermal imaging cameras to test electrical systems. *IEEE International Conference and Workshop in Obuda on Electrical and Power Engineering*, pp. 147–151.
- 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)*, pp. 853–858.

- Hesamian, G. (2016). One-way ANOVA based on interval information. *International Journal of Systems Science*, 47(11):2682–2690.
- Hinojosa, S., Pajares, G., Cuevas, E., y Ortega-Sanchez, N. (2018). Thermal image segmentation using evolutionary computation techniques. *Studies in Computational Intelligence*, 730:63–88.
- Holland, S. D. y Reusser, R. S. (2016). Material Evaluation by Infrared Thermography. *Annual Review of Materials Research*, 46(February):287–303.
- Homack, S. R. (2001). Understanding what ANOVA post hoc tests are, really. *Annual Meeting of the Southwest Educational Research Association*, pp. 1–15.
- Hsieh, S.-J. (2014). Survey of thermography in electronics inspection. *Thermosense: Thermal Infrared Applications XXXVI*, 9105:91050P.
- Hu, J. J., Li, H. C., y Tai, H. M. (2012). Thermal distribution monitoring of the container data center by a fast infrared image fusion technique. *Computers and Mathematics with Applications*, 64(5):1484–1494.
- Huda, A. S. y Taib, S. (2013). Suitable features selection for monitoring thermal condition of electrical equipment using infrared thermography. *Infrared Physics and Technology*, 61:184–191.
- Huda, A. S. N., Taib, S., Jadin, M. S., e Ishak, D. (2012). A semi-automatic approach for thermographic inspection of electrical installations within buildings. *Energy and Buildings*, 55:585–591.
- 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.
- Ibarra-Castanedo, C., Genest, M., Piau, J.-M., Guibert, S., Bendada, A., y Maldague, X. P. V. (2007). ACTIVE INFRARED THERMOGRAPHY TECHNIQUES FOR THE NON-DESTRUCTIVE TESTING OF MATERIALS. En *Ultrasonic and Advanced Methods for Nondestructive Testing and Material Characterization*, número 5, pp. 325–348. WORLD SCIENTIFIC.
- Ibarra-castanedo, C. y Maldague, X. P. V. (2013). *Handbook of Technical Diagnostics*. Sprin-

ger Berlin Heidelberg, Berlin, Heidelberg.

- Ibraheem, N. a., Hasan, M. M., Khan, R. Z., y Mishra, P. K. (2012). Understanding Color Models : A Review. *ARNP Journal of Science and Technology*, 2(3):265–275.
- Jadin, M. S., Taib, S., y Ghazali, K. H. (2014). Feature extraction and classification for detecting the thermal faults in electrical installations. *Measurement: Journal of the International Measurement Confederation*, 57:15–24.
- Jadin, M. S., Taib, S., y Ghazali, K. H. (2015). Finding region of interest in the infrared image of electrical installation. *Infrared Physics & Technology*, 71(January):329–338.
- Jain, A. K., Duin, R. P., y Mao, J. (2000). Statistical pattern recognition: A review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(1):4–37.
- Janecek, A., Gansterer, W. N., Demel, M., y Ecker, G. (2008). On the Relationship Between Feature Selection and Classification Accuracy. En *JMLR*, volumen 4, pp. 90–105.
- Janssens, O., Schulz, R., Slavkovikj, V., Stockman, K., Loccufer, M., Van De Walle, R., y Van Hoecke, S. (2015). Thermal image based fault diagnosis for rotating machinery. *Infrared Physics and Technology*, 73:78–87.
- Jia, Z., Liu, Z., Vong, C. M., y Pecht, M. (2019). A Rotating Machinery Fault Diagnosis Method Based on Feature Learning of Thermal Images. *IEEE Access*, 7(c):12348–12359.
- Jin, C., Bai, X., Yang, C., Mao, W., y Xu, X. (2020). A review of power consumption models of servers in data centers. *Applied Energy*, 265(March):114806.
- Jorge Dagnino, S. (2014). Comparaciones múltiples. *Revista Chilena de Anestesia*, 43(4):311–312.
- Khalid, S., Khalil, T., y Nasreen, S. (2014). A survey of feature selection and feature extraction techniques in machine learning. En *2014 Science and Information Conference*, pp. 372–378. IEEE.
- 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, D., Youn, J., y Kim, C. (2015). Automatic Fault Recognition of Photovoltaic Modules

- Based on Statistical Analysis of UAV Thermography. *Journal of the Korean Society of Surveying*, 34(6).
- Kim, T. K. (2017). Understanding one-way anova using conceptual figures. *Korean Journal of Anesthesiology*, 70(1):22–26.
- Kumar, S., Dolev, E., y Pecht, M. (2010). Parameter selection for health monitoring of electronic products. *Microelectronics Reliability*, 50(2):161–168.
- 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.
- Kumar, S. y Mahto, D. (2013). Recent Trends In Industrial And Other Engineering Applications Of Non Destructive Testing: A Review. *International Journal of Scientific and Engineering Research*, 4(9):183–195.
- Kurukuru, V. S., Haque, A., y Khan, M. A. (2019a). Fault Classification for Photovoltaic modules using Thermography and Image Processing. *2019 IEEE Industry Applications Society Annual Meeting, IAS 2019*, pp. 1–6.
- Kurukuru, V. S. B., Haque, A., Khan, M. A., y Tripathy, A. K. (2019b). Fault classification for Photovoltaic Modules Using Thermography and Machine Learning Techniques. En *2019 International Conference on Computer and Information Sciences (ICCIS)*, pp. 1–6. IEEE.
- Kwon, S., Han, S., y Lee, S. (2013). A small review and further studies on the LASSO. *Journal of the Korean Data and Information Science Society*, 24(5):1077–1088.
- Law, J., Morris, D. E., Budge, H., y Michael E., S. (2018). Infrared thermography. *Brown Adipose Tissue*, 251(07):49–54.
- Lee, E. K., Viswanathan, H., y Pompili, D. (2018a). Model-Based Thermal Anomaly Detection in Cloud Datacenters Using Thermal Imaging. *IEEE Transactions on Cloud Computing*, 6(2):330–343.
- Lee, H., Park, Y. M., y Lee, S. (2015). Principal Component Regression by Principal Component Selection. *Communications for Statistical Applications and Methods*, 22(2):173–180.

- Lee, S. W., An, K. E., Jeon, B. D., Cho, K. Y., Lee, S. J., y Seo, D. (2018b). Detecting faulty solar panels based on thermal image processing. *2018 IEEE International Conference on Consumer Electronics, ICCE 2018*, 2018-Janua:1–2.
- Li, K., Yun Tian, G., y Wang, Y. (2019). Imaging-based NDT Methods for Electronic Devices. *Proceedings of 2019 IEEE Far East NDT New Technology and Application Forum, FENDT 2019*, pp. 53–58.
- Liu, C., Cichon, A., Królczyk, G., y Li, Z. (2022). Technology development and commercial applications of industrial fault diagnosis system: a review. *The International Journal of Advanced Manufacturing Technology*, 118(11-12):3497–3529.
- 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.
- Liu, H., Lee, E. K., Pompili, D., y Kong, X. (2013). Thermal camera networks for large datacenters using real-time thermal monitoring mechanism. *The Journal of Supercomputing*, 64(2):383–408.
- Liu, H., Ran, J., Xie, T., y Gao, S. (2017a). Thermal feature extraction of servers in a datacenter using thermal image registration. *Infrared Physics and Technology*, 85:133–140.
- Liu, H., Xie, T., Ran, J., y Gao, S. (2017b). An Efficient Algorithm for Server Thermal Fault Diagnosis Based on Infrared Image. *Journal of Physics: Conference Series*, 910(1).
- 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*.
- Luqman, M., Zakariya, A.-H., y Mohammad, A. (2018). An Efficient Stator Inter-Turn Fault Diagnosis Tool for Induction Motors. *Energies*.
- Ma, J. y Yuan, Y. (2019). Dimension reduction of image deep feature using PCA. *Journal of Visual Communication and Image Representation*, 63(July).
- Maciel, G., Aquino, R., y Lira, M. (2017). Thermography and artificial intelligence in transformer fault detection. *Electrical Engineering*.
- Mahfurdz, A., Saher, R., Ghani, W., y Pi, W. (2020). Electronic Circuit Failure Detection

- Using Thermal Image. *Open Access Library Journal*, 7:1–7.
- Maldague, X. P. V. (1993). *Nondestructive Evaluation of Materials by Infrared Thermography*. Springer London, London.
- 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*, pp. 143–147.
- Mansley, C., Connell, J., Isci, C., Lenchner, J., Kephart, J. O., McIntosh, S., y Schappert, M. (2011). Robotic mapping and monitoring of data centers. En *2011 IEEE International Conference on Robotics and Automation*, pp. 5905–5910. IEEE.
- Marinetti, S. y Cesaratto, P. G. (2012). Emissivity estimation for accurate quantitative thermography. *NDT and E International*, 51:127–134.
- Mboo, C. P. y Hameyer, K. (2016). Fault Diagnosis of Bearing Damage by Means of the Linear Discriminant Analysis of Stator Current Features From the Frequency Selection. *IEEE Transactions on Industry Applications*, 52(5):3861–3868.
- McAndrew, A. (2015). *A computational introduction to digital image processing, second edition*. CRC Press, 2nd edición.
- McHugh, M. L. (2011). Multiple comparison analysis testing in ANOVA. *Biochemia Medica*, 21(3):203–209.
- Mulak, P. y Talhar, N. (2015). Analysis of Distance Measures Using K-Nearest Neighbor Algorithm on KDD Dataset. *International Journal of Science and Research*, 4(7):2319–7064.
- 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)*, pp. 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(2):615–625.
- Palimkar, N. y Bhole, A. A. (2016). “Fault Prediction in Electrical Equipments using Thermographic Inspection”. *International Journal of Engineering Research and Technology*, 5(04):685–687.
- Paolanti, M. y Frontoni, E. (2020). Multidisciplinary Pattern Recognition applications: A review. *Computer Science Review*, 37:100276.
- Parhizkar, T., Rafeipour, E., y Parhizkar, A. (2021). Evaluation and improvement of energy consumption prediction models using principal component analysis based feature reduction. *Journal of Cleaner Production*, 279(August):123866.
- Pertet, S. y Narasimhan, P. (2005). Causes of Failure in Web Applications. Technical Report 12.
- 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.
- Prakash, R. V. (2012). *Infrared Thermography*. InTech.
- Pratt, W. (2007). *Digital Image Processing*.
- Prieto-Moreno, A., Llanes-Santiago, O., y García-Moreno, E. (2015). Principal components selection for dimensionality reduction using discriminant information applied to fault diagnosis. *Journal of Process Control*, 33:14–24.
- Rakueangdet, 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(1):372–375.
- Raschka, S. (2014). An Overview of General Performance Metrics of Binary Classifier Systems. *arXiv*, abs/1410.5:1–5.
- Raudys, S. (2001). *Statistical and neural classifiers: An integrated approach to design*. Springer-Verlag London.
- Resendiz-Ochoa, E., Osornio-Rios, R. A., Benitez-Rangel, J. P., Romero-Troncoso, R. D. E. J., y Morales-Hernandez, L. A. (2018). Induction Motor Failure Analysis : An

- Automatic Methodology Based on Infrared Imaging. *IEEE Access*, 6:76993–77003.
- Rhyne, T. M. (2017). *Applying color theory to Digital Media and Visualization*. CRC Press.
- Ringnér, M. (2008). What is principal component analysis? *Nature Biotechnology*, 26(3):303–304.
- Salazar, A. M. y Macabebe, E. Q. B. (2016). Hotspots Detection in Photovoltaic Modules Using Infrared Thermography. *MATEC Web of Conferences*, 70.
- Salem, N. y Hussein, S. (2019). Data dimensional reduction and principal components analysis. *Procedia Computer Science*, 163:292–299.
- Sanati, H., Wood, D., y Sun, Q. (2018). Condition monitoring of wind turbine blades using active and passive thermography. *Applied Sciences (Switzerland)*, 8(10).
- Sankar, S., Shaw, M., Vaid, K., y Gurumurthi, S. (2013). Datacenter Scale Evaluation of the Impact of Temperature on Hard Disk Drive Failures. *ACM Transactions on Storage*, 9(2):1–24.
- Saravanan, R. y Sujatha, P. (2018). A State of Art Techniques on Machine Learning Algorithms : A Perspective of Supervised Learning Approaches in Data Classification. *2018 Second International Conference on Intelligent Computing and Control Systems*, pp. 945–949.
- Sarawade, A. A. y Charniya, N. N. (2019). Detection of Faulty Integrated Circuits in PCB with Thermal Image Processing. En *2019 International Conference on Nascent Technologies in Engineering (ICNTE)*, número Icn-te, pp. 1–6. IEEE.
- Sarstedt, M. y Mooi, E. (2019). Regression Analysis. En *Angewandte Chemie International Edition*, Springer Texts in Business and Economics, pp. 209–256. Springer Berlin Heidelberg, Berlin, Heidelberg.
- Shahzad, M., Bharath K., V. S., Khan, M. A., y Haque, A. (2019). Review on Reliability of Power Electronic Components in Photovoltaic Inverters. *2019 International Conference on Power Electronics, Control and Automation, ICPECA 2019 - Proceedings*, 2019-Novem.
- Sharma, A., Jigyasu, R., Mathew, L., y Chatterji, S. (2018). Bearing Fault Diagnosis Using Weighted K-Nearest Neighbor. En *2018 2nd International Conference on Trends in*

- Electronics and Informatics (ICOEI)*, número Icoei, pp. 1132–1137. IEEE.
- 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.
- Shawal, M. y Taib, S. (2012). Recent progress in diagnosing the reliability of electrical equipment by using infrared thermography. *Infrared Physics and Technology*, 55(4):236–245.
- Shereena, V. y David, J. M. (2015). Comparative Study of Dimensionality Reduction Techniques Using PCA and LDA for Content Based Image Retrieval. *Computer Science & Information Technology*, pp. 41–55.
- Shobha, G. y Rangaswamy, S. (2018). *Machine Learning*, volumen 38. Elsevier B.V., 1 edición.
- Singh, G., Anil Kumar, T. C., y Naikan, V. N. (2016). Induction motor inter turn fault detection using infrared thermographic analysis. *Infrared Physics and Technology*, 77:277–282.
- Smith, P. R. A. (2015). Non-Destructive Testing (NDT) – Guidance Document: An Introduction to NDT Common Methods. *British Institute of NDT*, (2):59.
- Song, F. F., He, X., y En, Y. (2014). The function of IR thermal imaging technology for device and circuit reliability research. *2014 IEEE International Conference on Electron Devices and Solid-State Circuits, EDSSC 2014*, pp. 2–3.
- Stoynova, A., Bonev, B., y Brayonov, N. (2018). Thermographic Approach for Reliability Estimation of PCB. *Proceedings of the International Spring Seminar on Electronics Technology*, 2018-May:1–7.
- 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]*, pp. 1–3.
- Sun, J., Wang, Z., Xie, C., Duan, C., y Li, T. (2019a). Application of Infrared Non-destructive Defect Location in Components. *2019 IEEE 3rd International Conference on Circuits, Systems and Devices, ICCSD 2019*, pp. 177–181.

- Sun, Y., Li, L., Zheng, L., Hu, J., Li, W., Jiang, Y., y Yan, C. (2019b). Image classification base on PCA of multi-view deep representation. *Journal of Visual Communication and Image Representation*, 62:253–258.
- 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.
- Tharwat, A. (2018). Classification assessment methods. *Applied Computing and Informatics*, 17(1):168–192.
- Tibshirani, R. (1996). Regression Shrinkage and Selection via the Lasso. *Journal of the Royal Statistical Society*, 58(1):267–288.
- Ullah, I., Khan, R. U., Yang, F., y Wuttisittikulkij, L. (2020). Deep learning image-based defect detection in high voltage electrical equipment. *Energies*, 13(2):17.
- 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).
- 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.
- Usamentiaga, R., Venegas, P., Guerediaga, J., Vega, L., Molleda, J., y Bulnes, F. G. (2014). Infrared thermography for temperature measurement and non-destructive testing. *Sensors (Switzerland)*, 14(7):12305–12348.
- Vollmer, M. y Möllmann, K.-P. (2018). *Infrared Thermal Imaging - Fundamentals, Research and Applications*. Wiley-VCH.
- Wang, H., Ma, K., y Blaabjerg, F. (2012). Design for reliability of power electronic systems. *IECON Proceedings (Industrial Electronics Conference)*, pp. 33–44.
- Wang, J. y Zhao, C. (2019). Broad Learning System Based Visual Fault Diagnosis for Electrical Equipment Thermography Images. *Proceedings 2018 Chinese Automation Congress, CAC 2018*, pp. 1632–1637.

- Webb, A. R. (2002). *Statistical Pattern Recognition: Second Edition*, volumen 2. John Wiley & Sons.
- Widodo, A., Satrijo, D., Huda, M., Lim, G. M., y Yang, B. S. (2011). Application of self organizing map for intelligent machine fault diagnostics based on infrared thermography images. *Proceedings - 2011 6th International Conference on Bio-Inspired Computing: Theories and Applications, BIC-TA 2011*, pp. 123–128.
- Williams, L. J. y Abdi, H. (2014). Tukey's Honestly Significant Difference (HSD). *Encyclopedia of Research Design*, (June):2–7.
- Wisyobunri, B. N., Erden, H. S., y Toreyin, B. U. (2020). A Deep Learning Approach to Fault Detection and Classification in Data Centers. En *Basarim2020 High Performance Computing Conference*, número December, pp. 1–6.
- Wronkowicz, A. (2016). Approach to automated hot spot detection using image processing for thermographic inspections of power transmission lines. *Diagnostyka*, 17(2):81–86.
- Xue, B., Zhang, M., Browne, W. N., y Yao, X. (2016). A Survey on Evolutionary Computation Approaches to Feature Selection. *IEEE Transactions on Evolutionary Computation*, 20(4):606–626.
- 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*, pp. 400–404.
- Zhang, S. y Wang, M. (2003). Server Classifications. En *Encyclopedia of Information Systems*, volumen 4, pp. 57–69. Elsevier.
- Zhang, Y. y Fjeld, M. (2020). Condition Monitoring for Confined Industrial Process Based on Infrared Images by Using Deep Neural Network and Variants. En *Proceedings of the 2020 2nd International Conference on Image, Video and Signal Processing*, número March, pp. 99–106, New York, NY, USA. ACM.

Anexos

A . Información de base de datos

Información de base de datos.

Información		
Cámara	FLIR E8	<p>Emisividad: 0.64 (hierro fundido) Distancia focal: 0,6 Modo de imagen: MSX Medición: punto caliente automático Color: Arco iris Rango de temperatura: Automático Procesador: Intel Xeon E5520 * 2; 16 núcleos; Caché L3 de 3,26 GHz 8 MB</p>
	DELL 720	<p>Memoria: 16G DDR3 ECC REG (4GB * 4); hasta 18 ranuras de memoria de 288G Hard Drive: 600 GB SAS 15000 RPM 3.5”(146G * 4); Support Six SAS SATA Modo de imagen: MSX Tarjeta madre: chips Intel 5520</p>
Fallas	1SX	60 % de carga de CPU: 60 % de uso de CPU, puerta de malla en la entrada del servidor, los ventiladores del servidor funcionan con normalidad
	2OH	100 % de carga de CPU: 100 % de uso de CPU, puerta de malla en la entrada del servidor, los ventiladores del servidor funcionan con normalidad
	3MF	El ventilador principal deja de funcionar: 60 % de uso de la CPU, puerta de malla en la entrada del servidor, ventilador del servidor principal apagado
	4CF	El ventilador de la CPU deja de funcionar: 60 % de uso de la CPU, puerta de malla en la entrada del servidor, el segundo ventilador en el lado izquierdo del servidor apagado, el resto de los ventiladores funcionando normalmente
	5EB	Bloqueo en la entrada del servidor: 60 % de uso de CPU, puerta de vidrio en la entrada del servidor, ventiladores del servidor funcionando normalmente

B. Código para segmentación

```
1 clc;
2 close all;
3 clear;
4
5 [names]=textread('5EBdata.txt','\%s','delimiter',' ','');
6 for k=1:length(names);
7 names(k);
8 mkdir(['','/',' ','/',' ','/',' ','/','names{k}(1:end-4)']);
9 movefile(names{k},['','/',' ','/',' ','/',' ','/','names{k}(1:end-4)']);
10 leering = fullfile(['','/',' ','/',' ','/',' ','/','names{k}(1:end-4)'],'/','
    names{k});
11 img = imread(leering);
12
13 hsvImage = rgb2hsv(img);
14 hImage = hsvImage(:,:,1);
15 sImage = hsvImage(:,:,2);
16 vImage = hsvImage(:,:,3);
17
18 hueMask = (hImage >= 0.942) | (hImage <= 0.079);
19 saturationMask = (sImage >= 0) & (sImage <= 1.0);
20 valueMask = (vImage >= 0) & (vImage <= 1.0);
21 Mask = double(hueMask & saturationMask & valueMask);
22
23 x1 = 11;
24 x2 = 303;
25 y1 = 66;
26 y2 = 145;
```

```

27
28 Maskhotspotarea = Mask(y1:y2,x1:x2);
29 Mask = zeros(size(Mask)); Mask(66:66+size(Maskhotspotarea,1)-1,
    11:11+size(Maskhotspotarea,2)-1,:)= Maskhotspotarea;
30
31 structuringElement = strel('disk',1,0) ;
32 MaskSE = imclose(Mask, structuringElement);
33 MaskSE = cast(MaskSE, 'double');
34
35 CompR = MaskSE .* img(:,:,1);
36 CompG = MaskSE .* img(:,:,2);
37 CompB = MaskSE .* img(:,:,3);
38 RGBImage = cat(3, CompR, CompG, CompB);
39
40 end

```

C . Código para extracción de características

```
1 [pixelCounts(:,k), GLs] = imhist(Comp);
2 NM(:,k) = sum(pixelCounts(:,k));
3 Pzi(:,k) = (pixelCounts(:,k)/NM(:,k));
4
5 Mean(k,:) = sum(GLs .* Pzi(:,k));
6 variance(k,:) = sum((GLs - Mean(k)).^2 .* Pzi(:,k));
7 stdDev(k,:) = sqrt(variance(k));
8 skew(k,:) = sum((GLs - Mean(k)).^3 .* (pixelCounts(:,k)/(NMR(:,
    k) .* stdDev(k).^3));
9 kurtosis(k,:) = (sum((GLs - Mean(k)).^4 .* (pixelCounts(:,k)/((
    NM(:,k) .* stdDev(k).^4)))-3;
10 ErgyR(k,:) = sum((( pixelCountsR(:,k))/(NMR(:,k))).^2);
11 EtrpyR(k,:) = - sum(((pixelCountsR(:,k))/(NMR(:,k))) (((
    pixelCountsR(:,k))/(NMR(:,k)))~=0) .* log2(((pixelCountsR(:,k)
    ))/(NMR(:,k))) (((pixelCountsR(:,k))/(NMR(:,k)))~=0)));
```

D. Algoritmo de ACP

```
1 library(readxl)
2 dataserver <- textshape::column_to_rowname(dataserver, loc = 1)
3 dataserver <- as.data.frame(dataserver)
4 dataserver <- subset(dataserver, select = -c(Condition))
5
6 KMO(cor(dataserver))
7
8 library(psych)
9 cortest.bartlett(cor(dataserver), n = nrow(dataserver2))
10
11 library(stats)
12 Pca <- prcomp(dataserver, scale = TRUE, center = TRUE)
```

E. Algoritmo de clasificación kNN

```
1 Pcadata <- Pca\${x[ ,1:2]}
2 Pcadata <- data.frame(Pcadata, condition= as.character(
   dataser\${Condition}))
3
4 randomdata <- sample(1:nrow(Pcadata), 0.8 * nrow(Pcadata))
5
6 normdata <-function(x) {(x -min(x))/(max(x)-min(x))}
7 Pcadata_norm <- as.data.frame(lapply(Pcadata[,c(1,2)], normdata)
   )
8
9 Pcadata_train <- Pcadata_norm[-randomdata,]
10
11 Pcadata_test <- Pcadata_norm[-randomdata,]
12
13 Pcadata_target_category <- Pcadata[randomdata,3]
14 Pcadata_test_category <- Pcadata[-randomdata,3]
15
16 library(class)
17 Knnmodel <- knn(Pcadata_train, Pcadata_test, cl= Pcadata_target_
   category, k=27)
```

F . Resultados del ACP

Resultados del análisis de componentes principales.

CP	EG		RGB		CMY		HSV		HSI		CIE L*a*b	
	1	2	1	2	1	2	1	2	1	2	1	2
Eigenvalor	6.9	0.10	20.5	0.27	20.1	0.57	20.7	0.23	20.5	0.31	20.8	0.11
Varianza (%)	99.0	0.80	97.6	1.30	95.7	2.70	98.5	1.10	97.8	1.50	99.0	0.50
V. acumulada (%)	99.0	-99.8	97.6	98.9	95.7	98.4	98.5	99.6	97.8	99.3	99.0	99.5
M (Canal 1)	0.38	-0.21	0.22	0.13	0.22	0.27	0.22	0.40	0.22	0.33	0.22	-0.24
V (Canal 1)	0.38	-0.47	0.22	0.16	0.20	0.54	0.22	0.41	0.22	0.34	0.22	-0.30
DE (Canal 1)	0.38	-0.37	0.22	0.20	0.20	0.53	0.22	0.37	0.22	0.30	0.22	-0.22
A (Canal 1)	-0.38	-0.46	-0.22	-0.23	-0.21	-0.23	-0.22	-0.28	-0.22	-0.23	-0.22	-0.14
C (Canal 1)	-0.38	-0.62	-0.22	-0.29	-0.21	-0.28	-0.22	-0.22	-0.22	-0.18	-0.22	-0.28
Er (Canal 1)	-0.38	-0.01	-0.22	-0.12	-0.22	0.07	-0.22	-0.01	-0.22	-0.02	-0.22	0.17
Et (Canal 1)	0.38	-0.04	0.22	0.11	0.22	-0.03	0.22	-0.04	0.22	-0.03	0.22	-0.20
M (Canal 2)			0.22	-0.19	0.22	-0.10	0.22	-0.09	0.22	-0.16	0.22	-0.13
V (Canal 2)			0.21	-0.47	0.22	-0.12	0.22	-0.21	0.22	-0.30	0.22	-0.04
DE (Canal 2)			0.21	-0.46	0.22	-0.13	0.22	-0.27	0.22	-0.35	0.22	0.05
A (Canal 2)			-0.22	-0.03	-0.22	0.16	-0.22	0.24	-0.22	0.32	-0.22	-0.12
C (Canal 2)			-0.22	0.00	-0.22	0.18	-0.22	0.35	-0.21	0.42	-0.22	-0.27
Er (Canal 2)			-0.22	-0.14	-0.22	0.06	-0.22	0.00	-0.22	-0.01	-0.22	0.17
Et (Canal 2)			0.22	0.11	0.22	-0.05	0.22	0.03	0.22	0.03	0.22	-0.20
M (Canal 3)			0.22	-0.13	0.22	-0.11	0.22	0.00	0.22	0.09	0.22	0.03
V (Canal 3)			0.22	-0.33	0.22	-0.15	0.22	-0.03	0.22	0.16	0.22	0.34
DE (Canal 3)			0.22	-0.31	0.22	-0.16	0.22	-0.08	0.22	0.12	0.22	0.42
A (Canal 3)			-0.22	-0.09	-0.22	0.14	-0.22	0.16	-0.22	0.11	-0.22	-0.13
C (Canal 3)			-0.22	-0.10	-0.22	0.17	-0.22	0.24	-0.22	0.16	-0.22	-0.29
Er (Canal 3)			-0.22	-0.09	-0.22	0.05	-0.22	0.00	-0.22	-0.01	-0.22	0.17
Er (Canal 3)			0.22	0.07	0.22	-0.04	0.22	0.00	0.22	0.02	0.22	-0.20

Nota. Componente principal (CP), escala de grises (EG), media (M), varianza (V), desviación estándar (DE), asimetría (A), energía (Er), entropía (Et)

G . Resultados VIF

Datos VIF para el modelo de regresión logística en datos escala de grises.

	SX	OH	MF	CF	EB
M	25,716	25,372	31,431	37,024	175,979
V	25,405	31,687	28,309	34,649	43,796
DE	7,799	13,502	9,691	12,286	28,612
A	12,315	11,405	16,986	21,002	90,206
C	4,650	4,422	6,488	8,085	30,726
Er	21,992	31,100	27,267	58,640	864,719
Et	10,631	14,633	15,025	26,921	411,662

Datos VIF para el modelo de regresion logística en datos RGB.

	SX	OH	MF	CF	EB
MR	204,485	245,016	767,669	312,251	1,187,925
VR	299,431	371,779	634,931	350,279	1,581,409
DER	144,563	180,795	252,003	160,932	665,750
AR	64,450	113,191	1,025,954	247,670	226,831
CR	31,119	56,335	470,440	123,624	110,656
ErR	31,517	33,912	47,927	38,115	234,820
EtR	561	677	1,762	1,634	4,607
MG	4,808	6,545	13,342	9,575	16,467
VG	8,061	13,810	17,808	12,893	21,066
DEG	6,928	12,392	15,496	9,304	16,730
AG	3,653	4,845	7,371	7,250	23,208
CG	1,911	2,509	3,717	3,480	11,435
ErG	30,953	41,609	66,226	47,803	208,514
EtG	28,228	38,089	59,980	45,793	214,125
MB	15,025	15,590	12,475	12,942	111,661
VB	12,538	14,743	18,114	13,156	57,454
DEB	7,909	9,754	15,138	9,290	16,651
AB	10,159	10,897	7,897	7,659	64,204
CB	4,487	5,004	3,299	3,198	26,094
ErB	34,116	37,178	61,278	40,930	264,007
EtB	27,222	29,720	49,839	33,648	210,279

Datos VIF para el modelo de regresión logística en datos CMY.

	SX	OH	MF	CF	EB
MC	822	1,041	1,813	1,876	6,190
VC	3,991	6,327	10,648	24,686	8,774
DEC	3,901	6,439	11,041	22,357	8,071
AC	552	795	1,291	2,376	3,610
CC	231	321	553	997	1,484
ErC	8,912	11,249	25,572	16,146	76,406
EtC	11,336	14,307	32,470	23,666	96,498
MM	125,728	250,365	314,691	302,469	583,693
VM	63,906	80,584	158,238	80,973	200,585
DEM	49,098	46,744	81,894	69,814	80,045
AM	167,718	290,995	477,560	629,391	567,035
CM	82,931	135,065	221,277	280,144	262,364
ErM	47,719	111,638	132,026	612,961	484,852
EtM	3,392	5,524	10,123	82,614	14,182
MY	187,949	332,171	457,448	560,318	608,656
VY	78,955	123,663	266,998	218,345	213,658
DEY	30,474	43,145	83,272	114,373	74,464
AY	169,485	284,397	359,583	521,895	481,545
CY	72,779	121,113	148,179	223,751	206,179
ErY	46,502	110,735	120,800	177,181	417,376
EtY	1,801	2,383	3,725	2,767	13,520

Datos VIF para el modelo de regresión logística en datos HSV.

	SX	OH	MF	CF	EB
MH	7,541	15,882	5,884	20,290	134,802
VH	186,002	85,980	52,562	112,628	1,058,076
DEH	202,901	75,211	59,933	105,684	834,057
AH	209,590	103,192	111,487	130,748	446,793
CH	176,108	62,757	83,323	95,841	285,223
ErH	899	1,338	1,192	1,138	8,799
EtH	494	793	859	822	5,469
MS	183,254	214,310	222,257	285,599	1,207,424
VS	75,681	106,160	97,227	113,732	458,949
DES	47,144	50,620	63,306	69,360	154,000
AS	253,221	310,408	302,144	386,200	1,554,686
CS	120,887	156,503	150,185	189,524	744,731
ErS	2,261,759	3,198,625	2,970,029	4,143,917	25,128,700
EtS	2,179	3,487	2,862	4,555	23,017
MV	461,622	522,093	592,597	761,076	2,575,202
VV	284,100	366,667	582,224	391,294	1,969,179
DEV	107,732	140,102	364,999	212,019	857,775
AV	647,726	499,918	955,504	988,383	2,899,791
CV	334,827	256,700	507,964	520,106	1,453,714
ErV	2,622,572	3,721,060	3,530,172	4,873,015	30,573,264
EtV	7,183	10,913	9,229	13,996	90,871

Datos VIF para el modelo de regresion logística en datos HSI.

	SX	OH	MF	CF	EB
MH	13,486	34,634	11,263	30,116	128,035
VH	57,048	108,092	205,178	145,835	665,017
DEH	54,118	90,322	224,447	106,172	546,913
AH	68,527	107,335	279,603	104,317	479,511
CH	40,464	63,248	238,608	69,999	246,980
ErH	882	1,782	1,718	1,707	5,419
EtH	635	1,202	1,478	1,560	6,246
MS	67,985	102,826	113,371	136,100	409,149
VS	30,635	45,313	80,881	75,494	163,075
DES	15,989	22,554	53,683	52,457	55,991
AS	83,223	121,785	118,595	175,688	350,743
CS	42,154	59,283	62,048	91,078	155,123
ErS	4,325,548	5,673,676	4,607,467	13,539,455	273,730,373
EtS	2,217	3,192	2,523	6,003	87,946
MI	113,953	265,069	238,447	292,380	1,206,520
VI	66,302	154,952	143,645	158,866	525,337
DEI	16,392	37,508	37,776	36,181	70,341
AI	56,630	155,925	131,370	172,440	706,655
CI	20,127	54,550	45,824	58,681	263,949
ErI	4,199,152	5,482,647	4,429,273	13,067,856	264,830,191
EtI	10,842	19,771	13,764	23,532	141,230

*Datos VIF para el modelo de regresion logística en datos CIE L*a*b.*

	SX	OH	MF	CF	EB
ML	340,308	545,944	462,702	717,907	1,491,839
VL	151,925	212,758	176,419	351,194	706,990
DEL	40,019	38,537	46,759	94,631	154,439
AL	151,662	324,711	221,588	370,846	1,147,814
CL	45,368	101,892	69,455	121,487	374,158
ErL	20,982,549	422,787,618	12,588,550	20,530,459	191,657,584
EtL	5,265	36,957	6,899	8,279	79,628
Ma	629,314	1,120,621	910,045	1,528,563	3,477,800
Va	229,191	365,197	279,230	473,683	1,155,573
DEa	42,374	38,895	45,103	43,806	128,430
Aa	355,161	614,423	680,960	529,070	2,472,000
Ca	143,800	239,530	301,380	206,194	1,137,104
Era	208,513,246	520,130,674	352,529,873	595,408,552	3,478,788,467
Eta	7,652	21,832	9,337	38,010	189,646
Mb	411,124	536,483	587,583	483,435	2,206,300
Vb	132,287	191,329	184,760	171,029	934,926
DEb	16,950	22,329	17,919	19,287	129,439
Ab	301,797	425,875	410,168	600,803	1,560,993
Cb	124,985	191,866	168,755	269,198	618,508
Erb	192,770,745	365,494,420	346,568,084	568,832,396	2,522,168,420
Etb	2,549	4,995	5,698	8,652	33,806