UNIVERSIDAD NACIONAL DE COLOMBIA

Diagnóstico e identificación de fallas en motores industriales a través del análisis de imágenes termográficas

Hermes Alexander Fandiño Toro

Universidad Nacional de Colombia - Sede Manizales
Facultad de Ingeniería y Arquitectura
Departamento de Ingeniería Eléctrica, Electrónica y Computación
Manizales, Colombia
2012

Diagnóstico e identificación de fallas en motores industriales a través del análisis de imágenes termográficas

Hermes Alexander Fandiño Toro

Tesis presentada como requisito parcial para optar al título de:
Magister en Ingeniería

Director:
Dr. Ing. Julio César García Álvarez

Línea de Investigación:
Procesamiento Digital de Señales
Grupo de Investigación:
Grupo de Procesamiento y Reconocimiento de Señales

Universidad Nacional de Colombia - Sede Manizales
Facultad de Ingeniería y Arquitectura
Departamento de Ingeniería Eléctrica, Electrónica y Computación
Manizales, Colombia
2012

Diagnosis and identification of faults in industrial motors through the analysis of thermographic images

Hermes Alexander Fandiño Toro

A thesis presented for the degree of:
Master of Engineering - Industrial Automation

Supervisor:
Dr. Ing. Julio César García Álvarez

Research area:
Digital Signal Processing
Research Group:
Signal Processing and Recognition Group

National University of Colombia
Faculty of Engineering and Architecture
Department of Electrical, Electronic and Computing Engineering
Manizales, Colombia
2012

Dedicado a:

Cenith, Erasmo, Sugey, María José y William.

Agradecimientos

Este trabajo fue realizado en el Laboratorio de Vibraciones Mecánicas, a cargo del Grupo de Procesamiento y Reconocimiento de Señales, las secciones de Propagación y de Máquinas del Laboratorio de Electricidad y Electrónica y el Grupo de Propagación Electrónica Aplicada (PROPELA), y financiado por el proyecto: DESARROLLO DE UN SISTEMA PILOTO DE MANTENIMIENTO PREDICTIVO EN LA LÍNEA DE PROPULSIÓN DE LAS LANCHAS PATRULLERAS DE LA ARMADA NACIONAL MEDIANTE EL ANÁLISIS DE VIBRACIONES MECÁNICAS E IMÁGENES TERMOGRÁFICAS, identificado con código 1119-425-20795 de COLCIENCIAS, y financiado por la Armada Nacional de Colombia.

Le agradezco a Julio César García, por haber aceptado dirigir este trabajo; a los profesores Germán Castellanos y Hernán Benitez Restrepo, por su apoyo académico y en la difusión de los resultados obtenidos. A Óscar Cardona, David Cárdenas, Benhur Ortíz y José Francisco Ruíz, por los aportes y críticas que hicieron. Finalmente, le agradezco a quienes contribuyeron a que fuera posible mi permanencia en el programa de maestría; algunas de esas personas son Blanca Sevilla Isaza, Lina Sepúlveda Cano y Jorge Gómez García.

Resumen

Se describe una metodología de identificación y localización de fallos en máquinas rotativas utilizando procesamiento digital de imágenes termográficas. El trabajo incluye un esquema de adquisición de las imágenes, de preprocesamiento para reducir el ruido de fondo y de segmentación de regiones de interés, utilizando transformada watershed. Se extraen dos tipos de características; las primeras, de tipo estadístico, capturan información sobre intensidades de pixel; las segundas, de tipo direccional, capturan información sobre magnitudes y direcciones de propagación de calor en las regiones de interés. Se utilizan técnicas de aprendizaje supervisado y se hacen análisis de relevancia para seleccionar el conjunto de características más relevantes. Como resultado se obtienen subconjuntos de características que, extraídas de las regiones de interés, permiten tanto la identificación como la localización espacial de zonas donde se presentan los efectos térmicos debidos a los fallos.

Palabras clave: Termografía infrarroja, máquinas rotativas, mantenimiento predictivo, región de interés, características direccionales, características estadísticas.

Abstract

This work describes a methodology for identifying and locating faults in rotating machines using digital image processing techniques. The work includes an outline of image acquisition, preprocessing to suppress background noise and segmentation of regions of interest using watershed transform. Two types of features are extracted: the firsts, of statistical type, capture information about pixel intensities; the latter ones, of directional type, capture information about magnitudes and directions of propagation of heat in the regions of interest.
Supervised learning techniques and relevance analysis are implemented, to select the most relevant feature set. As a result, subsets of extracted features from regions of interest, allow both the identification and the spatial location of areas where thermal effects are due to failures.

Index terms: Infrared thermography, rotating machines, predictive maintenance, region of interest, directional features, statistical features.

Contenido

Agradecimientos IX

Resumen XI

Abstract XII

Lista de símbolos XVIII

1. Introducción 1

2. Adquisición de imágenes termográficas sobre máquinas rotativas 3

2.1. Aspectos preliminares . . . 3
2.2. Identificación de fallos utilizando imágenes termográficas . . . 4
2.2.1. Mantenimiento predictivo de máquinas rotativas . . . 4
2.3. Adquisición y filtrado de las imágenes de las imágenes termográficas . . . 7
2.4. Segmentación de imágenes termográficas . . . 8
2.5. Método propuesto de umbralización . . . 10
2.6. Segmentación utilizando transformada watershed . . . 12
2.7. Marco experimental . . . 14
2.7.1. Banco de pruebas . . . 15
2.7.2. Bases de datos . . . 15
2.7.3. Evaluación de las técnicas de filtrado . . . 17
2.7.4. Evaluación de la segmentación . . . 19
2.8. Resultados . . . 19
2.9. Conclusiones . . . 24

3. Extracción de características 25

3.1. Aspectos preliminares . . . 25
3.2. Características estadísticas . . . 25
3.3. Características direccionales . . . 26
3.4. Análisis de relevancia . . . 28
3.5. Marco experimental . . . 29
3.5.1. Selección óptima del ancho de bin en el histograma para el cálculo del centroide . . . 29

3.5.2. Análisis de conglomerados 30
3.5.3. Análisis de relevancia 31
3.6. Resultados 31
3.6.1. Resultados para el cálculo del ancho óptimo de bins 31
3.6.2. Análisis de conglomerados para las características estadísticas 31
3.6.3. Análisis de relevancia para las características direccionales 32
3.7. Conclusiones 33

4. Clasificación de fallos **35**
4.1. Aspectos preliminares 35
4.2. Análisis de PCA y selección de características 35
4.3. Escalamiento multidimensional 36
4.4. Marco experimental 36
4.4.1. Clasificación utilizando medidas direccionales 36
4.4.2. Clasificación utilizando medidas estadísticas 37
4.4.3. Proyecciones utilizando escalamiento multidimensional 37
4.5. Resultados 37
4.5.1. Análisis de relevancia para las medidas direccionales 37
4.5.2. Clasificación utilizando medidas estadísticas 38
4.5.3. Análisis utilizando escalamiento multidimensional 40
4.6. Conclusiones 41

5. Conclusiones generales **44**
5.1. Trabajos futuros 45

A. Anexo: Intervalos de confianza y tolerancia **46**

B. Anexo: Características estadísticas **47**
B.1. Medidas de tendencia central 47
B.2. Medidas de dispersión 48
B.3. Medidas de forma 48

C. Patrones binarios direccionales **49**
C.1. Experimentos basados en PBD para las imágenes termográficas 49

D. Anexo: Discusión académica **51**

Bibliografía **52**

Lista de Figuras

2-1. Diagrama de la metodología de preprocesamiento. 3
2-2. Enfoque de diagnóstico basado en modelos [5]. 5
2-3. Enfoque de diagnóstico basado en modelos [5]. 5
2-4. Representación tridimensional - Filtro Biortogonal 3/5. 7
2-5. Representación de ROIAB como una superficie topográfica, y de su tranformada watershed. 13
2-6. Esquema de una segmentación watershed basada en marcadores. 14
2-7. Banco de pruebas. Insertando pesos de masa arbitraria en los discos perforados se inducen dos tipos de fallos, llamados de acuerdo con el rodamiento más próximo. . 15
2-8. Comparación entre el mismo corte de la imagen antes y después de la extracción de la capa Y, que es la usada en el trabajo. 16
2-9. Comparación - resultados visuales del filtrado wavelet de las imágenes. 18
2-10. Relación entre el valor SSIM [44] Vs número de frames para las 2 metodologías de filtrado. 18
2-11. Regiones de interés seleccionadas arbitrariamente. 19
2-12. Intervalos de píxeles que son cuantizados, luego de aplicar a una imagen la metodología de umbralización multinivel propuesta. 20
2-13. Comparación entre la imagen original, para el corte de sobre ROIAB, y la imagen cuantizada luego de hacer la umbralización multinivel. El intervalo con los valores altos tras la cuantización se utiliza para binarizar la imagen. 21
2-14. Intervalos que genera el algoritmo de umbralización multinivel propuesto para $k = 1$, utilizando un conjunto reducido del total de las bases de datos para todas las condiciones. 21
2-15. Intervalos que genera el algoritmo de umbralización multinivel propuesto para diferentes valores de k, utilizando una imagen arbitraria del banco de pruebas. . . . 22
2-16. Resultado de la umbralizacin multinivel, con la consecuente identificacin de ROI relacionadas con puntos de calor. 23

3-1. Comparación del campo de gradiente field para la misma región de la imagen, bajo dos condiciones de operación diferentes. 27
3-2. Marco experimental de capítulo. 29
3-3. Pesos de relevancia para el total de las 360 direcciones de gradiente. 33

4-1. Comparación – error de clasificación para las características en orden de relevancia descendente, para las 5 ROIs determinadas con la segmentación (ROI12 = ROIAB). 39
4-2. Proyección con MDS para ROIAB antes y después de la selección de características. 41
4-3. Proyección con MDS para 20 características, luego de PCA para ROI4 y ROI5. Resultados con operador de Prewitt 42

C-1. Superposición de los PBD extraídos en imágenes en el mismo instante de tiempo, en las 3 condiciones consideradas. 50
C-2. Detalle del conjunto de píxeles que generan a una ángulo de 45 grados, los patrones binarios direccionales 34 y 221. 50

Lista de Tablas

2-1. Especificaciones de la cámara termográfica, video y de las secuencias de imágenes. 17
2-2. Valores de distancia (en metros) entre la cámara y el objetivo, según las especificaciones de FOV de la cámara. 17

3-1. Valores medios de la función *Silhouette* para el cálculo del centroide. 31
3-2. Valores promedio de la función $silh(i)$. 32
3-3. Pesos de relevancia para las características estadísticas para ROIAB. 33

4-1. Error de clasificación para ROIAB utilizando como características todos los 360 ángulos de gradiente. Los resultados tienen la forma: $\mu_\epsilon \pm \sigma_\epsilon$. 37
4-2. Error medio de clasificación (porcentaje) para 3 clases analizadas, antes y después de la selección de características. Los resultados tienen la forma: $\mu_\epsilon \pm \sigma_\epsilon$. 38
4-3. Tasas de acierto de clasificación, considerando una sola característica a la vez. . . . 40
4-4. Pesos de relevancia para las características estadísticas. 40

Lista de símbolos

Símbolos con letras griegas

Símbolo	Término	Unidad SI	Definición
γ	Asimetría	*Adimensional*	$\frac{E((x-E(X))^3)}{\sigma^{3/2}}$
κ	Curtosis	*Adimensional*	$\frac{E((x-E(X))^4)}{\sigma^4}$
σ	Desviación estándar	*Adimensional*	$\sum_D (x-\mu)^2 p(x)$

Abreviaturas

Abreviatura	Término
ECM	Error cuadrático medio.
DMA	Desviación media absoluta.
dpr	Besbalance en el primer rodamiento.
dsr	Desbalance en el segundo rodamiento.
FOV	*Field-Of-View* – Campo de visión (de la cámara).
IGF	Identificación generalizada de fallo.
ILF	Identificación localizada de fallo.
LS	*Lifting scheme* – Esquema lifting.
HDG	Histograma de gradientes.
MDS	*multidimemsional scaling* – Escalamiento multidimensional.
n.p.	Ningún preproceso.
normal	Condición de operación normal.
PBD	Patrones binarios direccionales.
PCA	*Principal component analysis* – Análisis de componentes principales.
RGB	Mapa de color *Red-Green-Blue*
PSNR	*Peak signal-to-noise ratio* – Relación señal a ruido pico.
ROI	*Region of interest* – Región de interés.
SSIM	*Structural Similarity* – Similaridad estructural.
YUV	Espacio de color definido en términos de una componente de luminancia (Y) y dos de crominancia.

1. Introducción

Las máquinas rotativas hacen parte de los elementos fundamentales para el funcionamiento de fábricas de manufactura, líneas de producción, plantas químicas e instalaciones de generación de energía. Las fallas para este tipo de máquinas se presentan debido al deterioro de piezas asociadas, como acoples, rodamientos, componentes de los motores y cargas, entre otras, relacionadas con desperfectos en la simetría del conjunto de la máquina. Un caso particular lo constituye el desbalance de masa, en el que una carga distribuida asimétricamente sobre el eje desplaza el centro de masa de los elementos acoplados al motor de su centro de rotación, generando vibraciones y "golpeteo" [19]. El objetivo principal de los programas de mantenimiento en máquinas rotativas es evitar su salida de operación. Esto se hace mediante dos estrategias: el mantenimiento correctivo y el preventivo. La primera estrategia implica la reparación de la pieza involucrada, lo que requiere de la salida de operación de la máquina mientras se hace la reparación. Por el contrario, con el mantenimiento preventivo, se toman medidas de forma anticipada basadas en la disponibilidad de datos estadísticos sobre la ocurrencia de fallos conocidos, los cuales se utilizan para la programación de jornadas de mantenimiento. Para los métodos de mantenimiento predictivo se puede utilizar alguno de los siguentes enfoques [17]:

- En los enfoques basados en estimaciones y confiabilidad, la ocurrencia de fallos se predice teniendo en cuenta que la distribución de eventos almacenados sobre una población de máquinas inspeccionadas es idéntica. Esto permite la consideración de modelos estadísticos de la confiabilidad de las máquinas. Este aspecto sugiere la utilización de métodos estadísticos para determinar la vida útil de los componentes inspeccionados. No obstante, pueden producirse costos innecesarios por el reemplazo de componentes con una vida útil significativa al momento de su reemplazo [16].

- En los enfoques de predicción de las condiciones de operación de la máquina, se involucra el modelado para describir la máquina y sus modos de fallo, como en el caso de los modelos de propagación de fracturas [24]. Este tipo de mantenimiento está basado en la caracterización de la diferentes condiciones de operación de la máquina, lo que permite tener una aproximación de la forma como se presenta un fallo para así optimizar el tiempo de disponibilidad de la máquina. Este enfoque considera también modelos generados directamente de datos obtenidos sobre condiciones de operación. Estos datos pueden ser señales de vibraciones [46], frecuencia natural y amplitud de acelaración [35]. El análisis de los modelos incluye representaciones como elementos finitos para el cálculo de la fatiga de elementos rodantes basado en su geometría, carga y velocidad [23].

La medición de estas condiciones se basa en los registros de la máquina utilizando equipos portables o de mano, y se compara con las especificadas para condiciones normales de operación, lo que puede constituir un proceso tedioso, pero que es muy utilizado por representar un bajo costo inicial [41]. Los enfoques tradicionales de inspección de máquinas rotativas se basan en señales acústicas y de vibración. Recientemente ha cobrado vigencia el análisis basado en termografía infrarroja, debido a que las metodologías de adquicisiíon de las caraterísticas para la identificación de fallos son completamente no invasivas. Para el caso de las máquinas rotativas, la mejor manera de caracterizar su comportamiento y evolución térmica es a través de la comparación entre los registros de temperatura obtenidos a partir de la simulación de un modelo de la máquina en presencia de un fallo inducido, y los datos obtenidos de la máquina real. Una forma de caracterizar este comportamiento es a través de métodos de simulación; sin embargo, esta labor puede tornarse muy compleja porque una máquina suele tener piezas con propiedades térmicas diferentes, y no en todos los casos es factible contar de antemano con un modelo tridimensional de la máquina, ni tampoco hacer un despiece de la misma para generar un modelo exclusivo para la aplicación.
Debido a lo anterior, para implementar una metodología de mantenimiento predictivo, necesariamente se deben considerar enfoques automatizados para la adquisición de datos en tiempo real, de modo que no ocurran imprecisiones o errores de paralaje entre jornadas de mantenimiento programadas [16]. Sin embargo, las metodologías existentes para la detección de fallos en máquinas rotativas basadas en análisis de termografía infrarroja consideran tanto las regiones de calor a analizar como el fondo, debido a que la adecuada segmetación de las zonas consideradas posibles fallos es aún tema de discusión, bien en forma de píxeles o de coeficientes que resulten de una transformación hecha sobre la imagen, de modo que no es posible aislar adecuadamente regiones de interés (ROIs) en las imágenes para localizar fallos; por el contrario, se utiliza de forma indiscriminada la información de toda una imagen, o de una región seleccionada manualmente por quien hace la inspección de forma manual.
Este trabajo presenta una nueva metodología de procesamiento digital de imágenes termográficas aplicada a la identificación de fallos en máquinas rotativas. Esto permite avanzar hacia el desarrollo de metodogías automáticas de detección temprana de fallos, y el desarrollo de esquemas de mantenimiento predictivo con los cuales el seguimiento de la máquina puede hacerse en tiempo real. La metodología consiste en identificar y localizar, en imágenes térmicas, las regiones de la máquina inspeccionada que presentan los mayores aumentos de temperatura, para caracterizar en esas regiones los cambios en las magnitudes y direcciones de propagación de calor, que ocurren por efecto de fallos mecánicos. La estructura del documento es la siguiente: en el capítulo 2 se describe la metodología para la adquisición de la imagen térmica requerida para el diagnóstico e identificación de fallas en motores industriales; en el capítulo 3 se analizan dos tipos de características para la detección de fallos; en el capítulo 4 se muestra la discriminancia de las características consideradas y en el capítulo 5 se presentan la conclusiones del trabajo y se proponen trabajos futuros.

2. Adquisición de imágenes termográficas sobre máquinas rotativas

2.1. Aspectos preliminares

En este capítulo se describe la metodología para la adquisición de la imagen térmica requerida para el diagnóstico e identificación de fallas en motores industriales. Los análisis tienen como principales ventajas que la adquisición de datos no requiere del contacto físico entre el sensor y la máquina inspeccionada, por lo que son totalmente no invasivos. La metodología, que se resume en la figura **2-1**, incluye los siguientes pasos: 1.) la adquisición de las imágenes térmicas a través de su extracción de las secuencias de video; 2.) filtrado, es decir, la transformación de los elementos de la imagen a un espacio de representación adecuado para suprimir el ruido de fondo y 3.), un algoritmo modificado de umbralización multinivel para detectar las regiones en las que ocurren las mayores variaciones de temperatura en las imágenes, como paso previo a la segmentación de ROIs.
El objetivo de este preprocesamiento es incrementar la precisión del registro de los aumentos de temperatura en las imágenes termográficas, para permitir una mejor identificación de fallos debidos en este caso, al desbalance en el eje en el motor. El diagnóstico de la condición de operación de la máquina se hace utilizando exclusivamente los datos obtenidos de las imágenes termográficas, lo que hace que esta metodología esté dentro del enfoque de mantenimiento predictivo basado en datos.

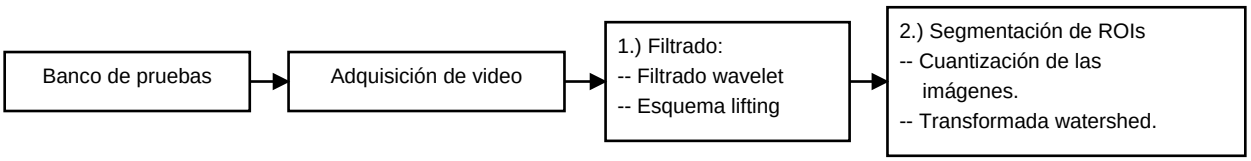

Figura 2-1.: Diagrama de la metodología de preprocesamiento.

El capítulo está organizado en la siguiente forma: en la sección 2.2 se muestran las aplicaciones que pueden tener las imágenes termográficas para la identificación de fallos en máquinas rotativas; en la sección 2.3 se describe la metodología de adquisición de las imágenes y se muestran las metodologías de filtrado utilizadas para mejorar la representación de las imágenes; en la

sección 2.4 se presentan algunas consideraciones que justifican la pertinencia de la metodología de umbralización; en la sección 2.5 se hace una breve descripción de las técnicas de umbralización, y se describen las circunstancias que motivan la elección de la metodología propuesta; en la sección 2.6 se describe la segmentación utilizada para las ROIs; en la sección 2.7 se describen las especificaciones de los experimentos, para obtener las bases de datos requeridas, y en la sección 2.8 se presentan los resultados de los mismos. Finalmente, en la sección 2.9 se presentan algunas conclusiones respecto a los experimentos.

2.2. Identificación de fallos utilizando imágenes termográficas

2.2.1. Mantenimiento predictivo de máquinas rotativas

La termografía infrarroja puede utilizarse para analizar un perfil anormal de temperatura que indique un fallo potencial en un objeto bajo inspección [25]. Esto ha mostrado ser útil para la identificación y caracterización de defectos en materiales, así como en pruebas de control de calidad, evaluaciones no destructivas, identificación y caracterización de defectos en soldaduras [27], y en aplicaciones médicas, como la asistencia al diagnóstico de cáncer de seno utilizando mamografía térmica [3].

Para el caso de las máquinas rotativas, los análisis basados en termografía infrarroja utilizan la temperatura como variable de medida que puede dar información sobre la condición de operación de la máquina. Esto se debe a que todas las máquinas tienen como parámetro su temperatura normal de operación, y cualquier incremento o decremento anormal de temperatura es un indicio de problemas en su funcionamiento [41]. La obtención de evidencia necesaria para diagnosticar fallos en máquinas rotativas, utilizando el mantenimiento predictivo, se hace mediante enfoques basados en modelos, y en señales o datos [5]:

En las aproximaciones basadas en modelos (ver figura **2-2**), se considera la diferencia entre las características extraídas de la simulación de un modelo de la máquina inspeccionada, y las mismas características obtenidas de la máquina real. Este tipo de enfoques puede implicar un trabajo muy complejo debido a que la máquina puede tener piezas con diferentes propiedades térmicas, lo que dificulta la generación del modelo y la caracterización de la máquina y de los fallos [43].

En las aproximaciones basadas en datos (ver figura **2-3**), se buscan cantidades medidas a partir de parámetros de la máquina como espectros de voltajes, velocidades o temperaturas, y se utilizan como indicadores de fallos. Las limitaciones de este tipo de métodos se relacionan con la naturaleza de las cantidades que se necesite medir, y de las implicaciones que suponga su obtención. Es el caso de los análisis basados en señales de vibración, en los que se requiere acoplar físicamente sensores a una máquina, pero no en todos los casos es factible el acceso a ciertos puntos de las máquinas para su implementación. Estos métodos no requieren de conocimiento sobre el modelo de la máquina; por el contrario los fallos son identificados mediante registros

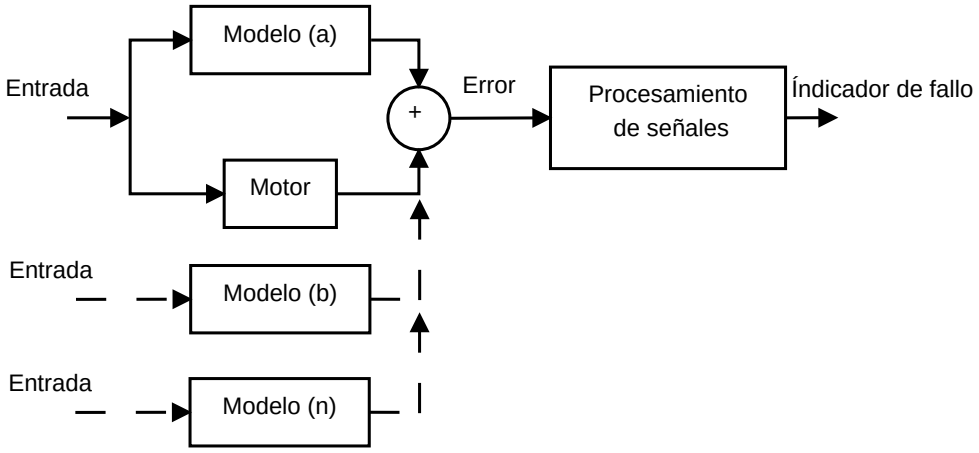

Figura 2-2.: Enfoque de diagnóstico basado en modelos [5].

obtenidos que son caracterizados y agrupados utilizando técnicas de reconocimiento de patrones.

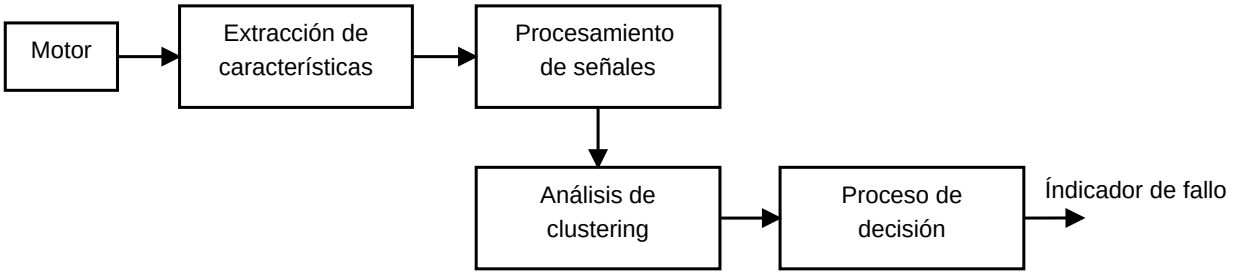

Figura 2-3.: Enfoque de diagnóstico basado en modelos [5].

Los análisis basados en termografía infrarroja utilizan estas dos aproximaciones, porque los registros de temperatura de una máquina pueden compararse con los de una simulación para determinar la presencia de un fallo y caracterizarlo (aproximación basada en modelos). Los registros pueden obtenerse durante inspecciones rutinarias para compararlos con valores especificados para condiciones de operación normal de la máquina (aproximación basada en datos). Finalmente, los registros obtenidos de la máquina pueden tomarse en diferentes condiciones de operación para generar historiales de temperatura con los cuales planificar jornadas de mantenimiento predictivo. Las metodologías automáticas para identificar y localizar los posibles fallos a partir de imágenes termográficas adquiridas sobre máquinas rotativas, son de reciente investigación. En la búsqueda realizada en este estudio, se encontraron los siguientes trabajos relevantes:

En [30], se analiza el efecto que tiene la inspección de imágenes termográficas tomadas en un mismo componente mecánico de una máquina para intervalos de tiempo distintos pero de la misma duración. Este trabajo muestra que la aplicación de transformaciones espacio-escala sobre las

imágenes permiten revelar diferencias morfológicas y dinámicas entre secuencias de imágenes, como producto de la modificación en la distribución de temperatura de las mismas, y que se producen al modificarse los valores de píxeles en las imágenes. También concluye que el análisis termográfico por sí mismo, es insuficiente para predecir anomalías relacionadas con sistemas mecánicos bajo análisis.

En [47], se propone la consideración de histogramas de coeficientes wavelet de aproximación que se obtienen de la descompisición de imágenes térmicas; la presencia de fallos se determina a partir del análisis sobre cambios en las distribuciones de probabilidad de los coeficientes obtenidos.

Este método tiene como limitación que no considera la extracción de ROIs en las imágenes de modo que no es posible obtener de forma automática la ubicación espacial del fallo en la máquina. Otra limitación tiene que ver con el tipo de características medidas en las imágenes, dado su carácter paramétrico. Por ejemplo, medidas como la curtosis y la asimetría tienen una clara interpretación cuando se consideran distribuciones de probabilidad normales, al igual que con la desviación estándar y la media de los datos. Pero con frecuencia ocurre que la distribución de probabilidad de los píxeles de una imagen no se ajusta a una distribución paramétrica, por lo que sin ningún conocimiento sobre la distribución probabilística de los píxeles, para efectos de interpretabilidad de resultados, deben considerarse preferiblemente medidas de tendencia central como la media y la media ponderada de los datos, y medidas de dispersión como la desviación estándar y la desviación media absoluta, tal como se propone en [9]. El método presenta además las limitaciones de un análisis multiresolución basado en transformada wavelet y que son la escogencia de la wavelet madre, y el nivel óptimo de descomposición.

En [45] se propone el uso de redes neuronales para la identificacíon de fallos en los rodamientos de una máquina rotativa. En dicho trabajo se utilizan como características el área, el perímetro y momentos centrales de ROIs, cuyas morfologías son segmentadas utilizando una metodología propuesta en [14], que a su vez se basa en el método de Otsu [33]. El trabajo tiene como limitaciones que los experimentos se hacen trabajando en el espacio de color RGB, lo que supone de antemano una dificultad asociada a la escogencia de la capa óptima en las imágenes para hacer el procesamiento de las mismas. Por otra parte, la utilización del método de umbralización de Otsu tiene limitaciones derivadas de la formulación original del método, y que impone restricciones respecto a la bimodalidad del histograma de la imagen, como requisito para hallar un umbral óptimo que permita la separación del objeto(s) en la imagen del fondo de la misma [22].

En este trabajo se sugiere como estrategia de localización espacial de fallos, la segmentación de ROIs y la extracción de características sobre estas y no sobre el conjunto total de la imagen. Se propone una metodología que resuelve los problemas descritos anteriormente, en la siguiente forma:

- Se utilizan transformadas wavelet para implementar una metodología de reducción de ruido de fondo. Del filtrado se obtienen imágenes que tienen las mismas dimensiones que la imagen original, pero con diferente relación señal a ruido pico (*Peak Signal - to - Noise*

Ratio – PSNR). Esto se hace para mejorar la representación de las imágenes sin perder la interpretabilidad de las mismas, por efecto de la transformación wavelet. En todos los experimentos que implican el filtrado de las imágenes, se utiza el filtro bidimensional, Biortogonal 3/5 (ver figura **2-4**).

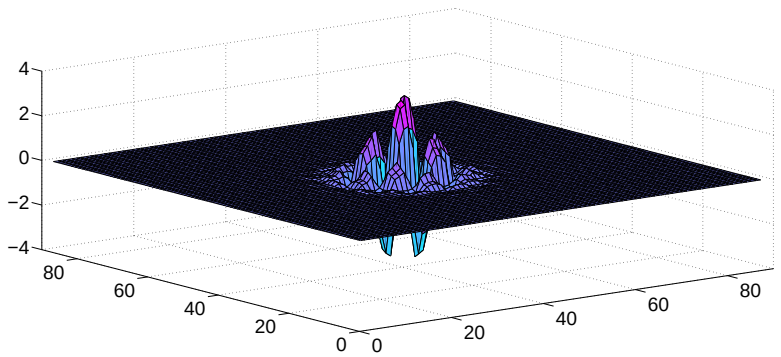

Figura 2-4.: Representación tridimensional - Filtro Biortogonal 3/5.

- Para localizar espacialmente los fallos se propone una metodología de segmentación basada en la identificación de las zonas con mayor variabilidad espacial de temperatura. Se utiliza la variabilidad de los píxeles en ciertas regiones del histograma de las imágenes para segmentar las ROIs del fondo. De este modo se enfocan los análisis hacia ROIs que se conoce previamente, son afectadas directamente por los efectos térmicos que producen los fallos mecánicos considerados. Estas ROIs se utilizan como marcadores con los que se hace una segmentación posterior utilizando la transformada watershed.

2.3. Adquisición y filtrado de las imágenes de las imágenes termográficas

Las imágenes se obtienen de una cámara que detecta la radiación emitida por la máquina en el rango infrarrojo del espectro electromagnético, y la convierte en un mapa térmico que puede utilizarse para detectar modos de degradación de la máquina manifiestados como aumentos de temperatura, por ejemplo los rodamientos, que por efecto de los desbalances inducidos para simular fallos, empiezan a deformarse y a presentar irregularidades en su superficie, produciendo incrementos en la fricción con las piezas en contacto con estos durante su operación y consecuentemente provocan aumentos de temperatura en partes de la máquina [16].

Existe evidencia de que para las imágenes termográficas, los procesos tales como filtrado y extracción de ruido afectan la calidad de las imágenes, siendo apreciables los efectos en los bordes. Para afrontar este problema, en [18] se considera la transformada wavelet discreta cuadrada y se propone la itilización de algunas bases wavelet ortogonales. La medición de desempeño fue

evaluada en términos del porcentaje de bordes y contornos que permanecen en la imagen después de la extracción del ruido. En [1], para el procesamiento de imágenes médicas se utiliza la función Daubechies basada en literatura previa en la cual se documenta acerca de descomposiciones estables y precisas para señales biomédicas. El éxito de los métodos basados en wavelet se debe a que las imágenes tienden a ser poco densas, lo que implica que las reconstrucciones basadas en un pequeño conjunto de wavelets son muy precisas [11].
En el trabajo presentado en [30] se concluye que la combinación de termografía infrarroja y transformadas wavelet en dos dimensiones permite revelar diferencias dinámicas y morfológicas mostradas por patrones térmicos diferentes encontrados en máquinas rotativas. En [48] se propone un filtro wavelet para aumentar la discriminancia de características estadísticas medidas sobre las distribuciones de probabilidad en los coeficientes del filtro, de cara a la identificación de fallos en máquinas rotativas. Para el mismo problema, en [45] se propone un acercamiento a la localización de fallos, implementando una técnica de umbralización para segmentar posibles ROIs, y focalizar la tarea del procesamiento.
En esta tesis se propone un filtrado de las imágenes con en fin de obtener los coeficientes de aproximación. De este modo se obtiene una representación que puede utilizarse para proseguir en la etapa de localización, que se hace mediante una modificación de una metodología de umbralización multinivel.

2.4. Segmentación de imágenes termográficas

Al segmentar una imagen se separan regiones o contornos, denominados objetos, mediante la identificación de características comunes. Dado que la propiedad más simple que pueden compartir los píxeles en la región de una imagen es la intensidad, una forma natural de separar las regiones es a través de una umbralización o separación de regiones claras y oscuras [29].
Una umbralización constituye una versión simple de segmentación en la que obtiene una versión umbralizada $g(x,y)$ de una imagen $I(x,y)$ a partir de un umbral T dado por:

$$g(x,y) = \begin{cases} 1 & \text{if } I(x,y) \geq T \\ 0 & \text{en cualquier otro caso} \end{cases} \tag{2-1}$$

Esta forma de umbralización se denomina *global*, y tiene como limitación que solo puede aplicarse a algunas imágenes, en las cuales la relación objeto-fondo de la imagen, es clara [34]. En la mayoría de los casos, se implementan técnicas de umbralización multinivel, en las que problema de la selección de los umbrales para cuantizar una imagen se puede interpretar como el de encontrar un conjunto $T(l), (l = 1, 2, ..., L)$ de valores de umbral, de modo que la imagen original $I(x,y)$

se transforme en una nueva con sólo J valores, es decir, si $T(l)$ son los valores de umbral para $T(1) \leq T(2), < ..., < T_L$, entonces, la imagen de salida se define como:

$$g(x,y) = \begin{cases} 0, & \text{si } I(x,y) \leq T(1) \\ 1, & \text{si } T(1) \leq I(x,y) \leq T(2) \\ & \vdots \\ L & \text{si } I(x,y) \geq T(L) \end{cases} \tag{2-2}$$

donde 0 y L representan los valores mínimo y máximo de la imagen, respectivamente [34].
Las técnicas de segmentación de imágenes pueden clasificarse dentro de los siguientes enfoques:

- **Segmentación supervisada, o basada en modelos,** en la cual se utiliza conocimiento previamente de objetos y del fondo de las imágenes para determinar la presencia o ausencia, de regiones específicas que se requiere segmentar. Este tipo de segmentación suele combinarse con etapas posteriores de reducción de falsos positivos (algoritmos de extracción de características combinados a su vez con clasificadores), lo que suele implicar la inclusión de etapas de entrenamiento en las cuales los algoritmos "aprenden" los objetos específicos que deben detectar, para luego clasificar imágenes dependiendo de la presencia o ausencia de objetos similares.

- **Segmentación no supervisada,** en la cual la se encuentran regiones de la imagen que son uniformes respecto a propiedades específicas como los niveles de gris, textura o color [31]. Existen a su vez enfoques para este tipo de segmentación, los cuales pueden divididirse en los siguientes grupos:

  1. **Métodos basados en regiones,** en los que la imagen se divide en regiones homogéneas, conectadas espacialmente. Usualmente este tipo de métodos implican la asignación de puntos semilla, asignados manualmente en regiones de interés definidas previamente. En este tipo de métodos se incluyen los enfoques de crecimiento de regiones, los métodos de tipo *split and merge* y los métodos basados en transformada watershed [37].

  2. **Métodos basados en contornos,** que se basan en las fronteras de las regiones consideradas. Tienen como desventaja, que se basan principalmente en la información de bordes de la imagen, los cuales en muchos casos no pueden ser completados satisfactoriamente, de modo que pueden formarse curvas no cerradas ni conexas que rodeen las regiones de interés [31]. En este sentido, pueden requerir de algoritmos para resaltar los bordes relevantes en la imagen, de forma previa a la etapa de detección.

  3. **Métodos basados en clustering,** que agrupan aquellos píxeles que tienen propiedades similares y que podrían dar lugar a la formación de regiones no conexas. Pueden

dividirse en **métodos jerárquicos,** que producen series de particiones anidadas, y en **métodos particionales,** que producen una sola partición. Aunque los métodos jerárquicos pueden ser más precisos, los métodos particionales se utilizan en aplicaciones que involucran grandes bases de datos. Estos últimos tienen dos grandes desvantajas: (1.) que el algoritmo tiene que conocer previamente el número de regiones que hay en la imagen y (2.), que los algoritmos de clustering no utilizan información espacial de la imagen. En este tipo de metodologías se encuentra el algoritmo de $k - means$.

En este estudio, las ROIs que se requieren segmentar deben presentar los valores de temperatura proporcionalmente más altos que contienen las imágenes, pues se presume que estos corresponden a las piezas de la máquina que están siendo afectadas por fallos mecánicos que producen incrementos anormales de temperatura. Se requiere el análisis de la silueta de la máquina, ya que es de interés obtener información sobre el área delimitada por el contorno de la máquina para establecer la localización espacial de los fallos. Por estas razones se utiliza un enfoque basado en regiones que incluye, primero, una umbralización multinivel para detectar las regiones de mayor calentamiento (*hot-spots*); aquellas que resultan de esta primera etapa se utilizan como marcadores para una segmentación basada en transformada watershed, con la que se obtiene una mejor representación de las ROIs.

2.5. Método propuesto de umbralización

En [4] se propone una umbralización multinivel para imágenes, considerando intervalos de tolerancia en la distribución de probabilidad de los píxeles. El algoritmo genera intervalos de forma iterativa, y a los píxeles dentro de estos se les asigna como valor la media ponderada (ver Anexo B.1.1) de los valores de píxeles en el intervalo. La formulación del algoritmo garantiza para cada iteración la existencia de intervalos disyuntos para valores “bajos y altos” de píxeles en la imagen que son cuantizados.

Las consideraciones basadas en los intervalos de tolerancia, al estar definidas en términos de medidas paramétricas como lo son μ y σ, dependen de la distribución de los píxeles en la imagen; si ésta es normal, entonces los intervalos definen proporciones de datos de tamaño fijo en la distribución probabilistica. Sin embargo esta condición no necesariamente se cumple en todos los casos, por lo que una umbralización basada completamente en los intervalos de tolerancia implica aceptar cierto error debido a particularidades de la distribución de probabilidad de los píxeles en las imágenes. En este estudio los intervalos con mayores variaciones de píxeles de valor alto, se utilizan para proponer regiones que sirven como marcadores en una segmentación posterior basada en transformada watershed. El algoritmo 2.5.1 describe la formulación original del método de umbralización; posteriormente se describen las modificaciones propuestas.

Algoritmo 2.5.1: Umbralización multinivel propuesta en [4]

entradas: n, que representa el número de umbrales que debe tener la imagen cuantizada; k, y la imagen a cuantizar.
salida : La imagen cuantizada.

1 **para** $i = 1 : (n-2)/2$ **hacer**
2 Se define el rango $\mathbf{R} = [a,b]$; incialmente $a = 0$; $b = 255$.
3 Encontrar la media (μ) y la desviación estándar (σ) de todos los píxeles en $\mathbf{R}$.
4 Se definen los umbrales $T_1 = \mu - k\sigma$ y $T_2 = \mu + k\sigma$, donde k es un parámetro libre.
5 A los píxeles dentro de $[a : T_1]$ y $[T_2 : b]$
se les asigna como valores la media ponderada de su respectivo intervalo.
6 $a = T_1 + 1$; $b = T_2 - 1$
7 **fin**
8 Finalmente, se repiten los pasos $2-5$ con $a = T_1 + 1$, $b = \mu$, y con $a = \mu + 1$, $b = T_2 - 1$.

Algoritmo 2.5.2: Umbralización multinivel modificada

entrada: La imagen a cuantizar *imOriginal* y k.
salida : La imagen cuantizada.

1 **mientras** $T_1 - T_2 \geq 2$ **hacer**
2 Se define el rango $\mathbf{R} = [a, b]$, incialmente $a = \text{mín}(imOriginal)$ y $b = \text{máx}(imOriginal)$.
3 Encontrar la media (μ) y desviación estándar (σ) de todos los píxeles en $\mathbf{R}$.
4 Se definen los umbrales $T_1 = \mu - k\sigma$ y $T_2 = \mu + k\sigma$, donde k es un parámetro libre.
5 A los píxeles dentro de $[a : T_1]$ y $[T_2 : b]$
se les asigna como valores la media ponderada de su respectivo intervalo.
6 $a = T_1 + 1$; $b = T_2 - 1$
7 **fin**

Las razones que motivan las modificaciones a la metodología descrita en el agoritmo 2.5.1 son las siguientes:
No interesa de forma particular la asignación un número determinado de umbrales en la imagen final (lo que supondría adicionar incertidumbre adicional al algoritmo). En este punto se lanza la hipótesis de que hay rangos de píxeles para los que ocurren las mayores variaciones en las imágenes, y que esos rangos hacen parte de los píxeles de las ROI. Para garantizar que se analize la mayor cantidad posible de intervalos de píxeles, se propone como criterio de parada inicial la conservación de una diferencia mínima de 2 entre los valores de T_2 y T_1 en cada iteración (ver algoritmo 2.5.2), de modo que las iteraciones no produzcan el traslape entre los intervalos. Esto motiva la modificación del paso 1.) del algoritmo original.
Por otra parte, la formulación original del algoritmo no fue hecha para imágenes termográficas, de modo que se asumen imágenes con píxeles cuyo rango de valores fluctúa entre 0 y 255. Este

no es el caso general de las imágenes termográficas, en las cuales dependiendo de la aplicación se pueden tener rangos de píxeles con variaciones menores a unas pocas decenas. Tal limitación motivó la modificación del paso 2.) del algoritmo 2.5.1.
Los algoritmos 2.5.1 y 2.5.2 están basados en la calidad de la representación de la imagen, descrita en términos de los intervalos de tolerancia en su histograma. Aunque no permite el traslape entre los intervalos, resulta claro que el valor del parámetro k introduce incertidumbre al problema, y que una escogencia errónea de dicho parámetro puede conducir a una cuantización poco precisa de la imagen, en el sentido que se puede obviar la verdadera variabilidad de los píxeles en cada uno de estos subintervalos.
Para justificar la escogencia del parámetro k en la umbralización, debe corroborarse: 1.), que sea posible utilizar el mismo valor para todas las imágenes, teniendo en cuenta todas las clases consideradas y 2.), que haya regularidad en los intervalos obtenidos para las imágenes. Esta corroboración se hace implementando la umbralización para un conjunto submuestreado de imágenes en las bases de datos a razón de una imagen cada 180 segundos, lo que da lugar a 18 imágenes por condición. Para la umbralización, se utiliza inicialmente $k = 1$.

2.6. Segmentación utilizando transformada watershed

Con frecuencia la segmentación basada en transformada watershed se explica con alguna una abstracción, en la que se piensa en la imagen como la representación de una superficie topográfica en la que el nivel de gris representa la altura sobre un relieve. Si existen fuentes independientes de agua que inundan la superficie a partir de los mínimos locales en el relieve, entonces el nivel de agua (de gris) aumentará hasta inundar completamente la superficie. Se asume que cada una de las distintas fuentes de agua tiene asignada una etiqueta. Antes de que dos regiones inundadas por fuentes diferentes (que en la transformada reciben el nombre de *catchment basins*) se toquen, se genera una región denominada *región watershed*, que no se toca con ninguna otra. Al final de la segmentación, las fronteras de las regiones watersheds, denominadas *líneas watershed*, definen los límites entre los objetos segmentados [37].
En la práctica, la transformada watershed no se aplica directamente sobre una imagen sin ningún tipo de preprocesamiento de la misma, pues el algoritmo tiende a sobresegmentarla (ver figura **2-5**). En su lugar, suele segmentarse la que contiene su gradiente morfológico [28], pues de este modo se producen regiones watersheds para puntos de discontinuidad controlados mediante algún preprocesamiento previo que evita la sobresegmentación de la imagen. El enfoque utilizado en este estudio es el denominado *segmentación watershed controlada por marcadores*, que hace uso de operaciones morfológicas para determinar el gradiente morfológico de la imagen y los *catchment basins* en los mínimos de la imagen de gradientes [6]. La secuencia de operaciones morfológicas es similar a la descrita en [14], y la transformada watershed es la propuesta en [28]. Esto se describe gráficamente en la figura **2-6**, cuya secuencia de pasos es la siguiente:

1. La computación de la función de segmentación se hace calculando los bordes de los objetos

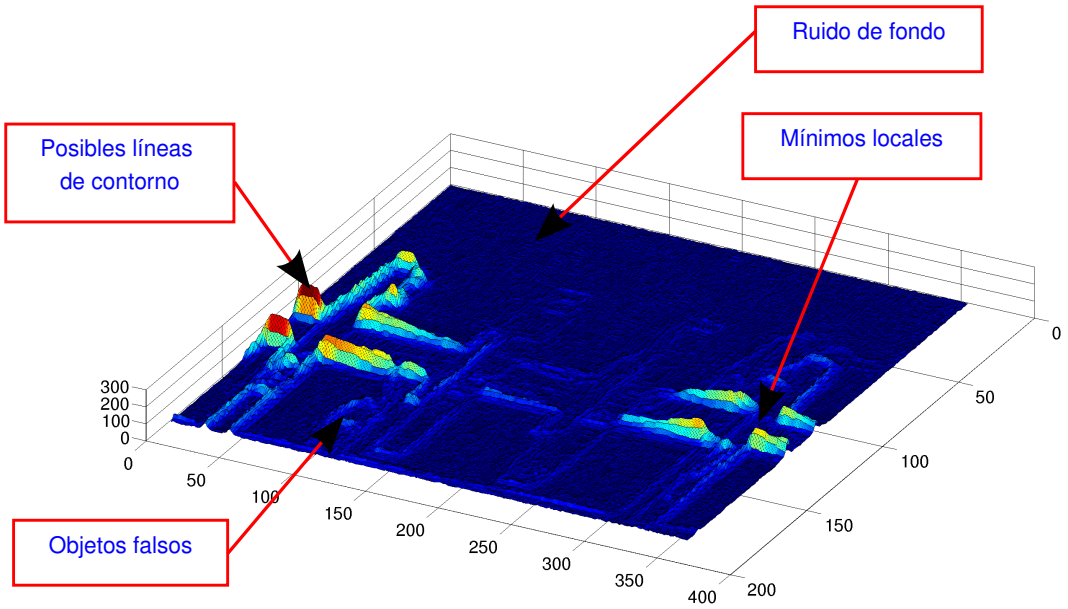

(a) Imagen original.

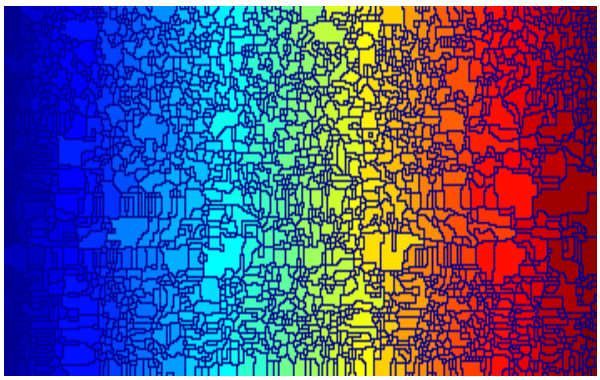

(b) Sobresegmentación de la imagen original, luego del cálculo de su transformada watershed.

Figura 2-5.: Representación de ROIAB como una superficie topográfica, y de su tranformada watershed.

que se quiere segmentar. Esto se hace obteniendo un mapa de contornos de la imagen basado en el detector de bordes de Sobel [39].

2. El término *marcadores* se refiere a indicadores de los objetos que se quieren detectar; los marcadores son necesarios pues la transformada detecta minímos en la imagen a partir de los cuales se generan las regiones watershed. El problema es que las imágenes suelen contener muchos mínimos locales (ver figura 2.5(a)), de modo que la transformada sobre la imagen sin ningún preproceso produce su sobresegmentación. Los marcadores para los objetos se obtienen implementando operaciones morfoloógicas comunes, como por ejemplo aperturas

basadas en reconstrucción.

3. Los marcadores para el fondo se obtienen calculando la transformada watershed de la transformada de distancia [26] de la imagen binarizada. Los puntos en los que la transformada watershed, de la tansformada de distancia son cero, determinan las líneas watershed. La binarización se hace con la umbralización modificada propuesta en el algoritmo 2.5.2.

4. Se modifica la imagen para que sólo tenga mínimos regionales en los píxeles del fondo y en los pertenecientes a los marcadores.

5. Se calcula la transformada watershed en la función de segmentación modificada. Esta imagen modificada difiere de la original sólo en sus mínimos regionales, en el sentido de que los únicos mínimos que contiene se encuentran dentro del conjunto de marcadores. La transformada que se calcula sobre la función de segmentación modificada es la propuesta en [28].

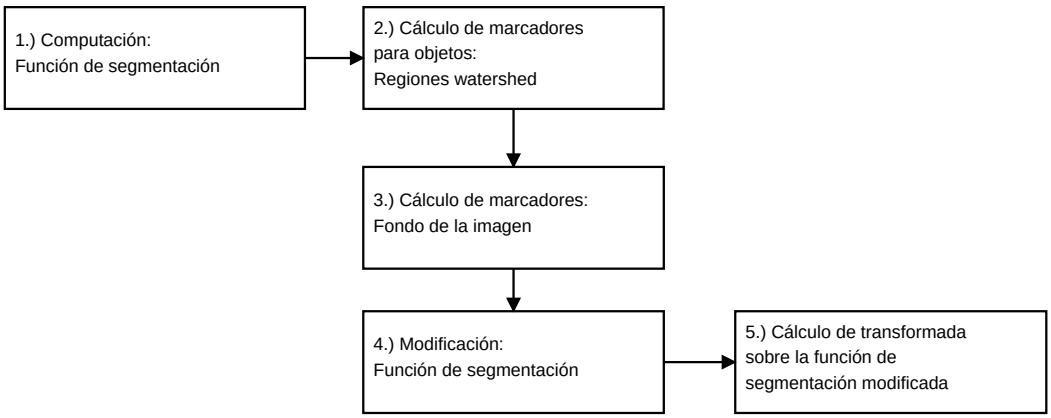

Figura 2-6.: Esquema de una segmentación watershed basada en marcadores.

2.7. Marco experimental

A continuación se describe la metodología implementada como paso previo al procesamiento para la identificación de fallos en máquinas rotativas. Esto incluye la disposición de un banco de pruebas, la generación de una base de datos de imágenes a partir de la descomposición de las grabaciones de video en secuencias de imágenes, el filtrado del ruido de fondo de las imágenes y finalmente la remoción del fondo de estas mediante la segmentación de ROIs. El objetivo del marco experimental es mejorar la calidad en la representación de los datos a partir de la cual se hacen el procesamiento que se describe en los capítulos siguientes.

2.7.1. Banco de pruebas

El banco de pruebas se presenta en la figura 2-7, y consta de un motor de inducción trifásico cuyo eje se encuentra unido mediante un acople rígido a otro eje que contiene 2 discos con perforaciones. Insertando pesos de masa arbitraria en las perforaciones se inducen dos tipos de desbalance: El primero, denominado **dpr**, se produce insertando pesos en el disco perforado más cercano, a 12 centímetros del acople; en el segundo caso, denominado **dsr**, se produce el desbalance insertando pesos en el rodamiento más lejano, a 43,5 centímetros del acople. En la tabla 2-1 se describen las especificaciones más relevantes respecto al diseño de los experimentos; aunque aparece relacionado un solo valor de emisividad, se aclara que dicho valor fue calculado experimentalmente para las superficies que comprenden los soportes del eje acoplado (ubicación para sensores de acelaración en la figura 2-7). Estas regiones son las mismas que se determinaron previamente como regiones de interés (ver figura 2-11).

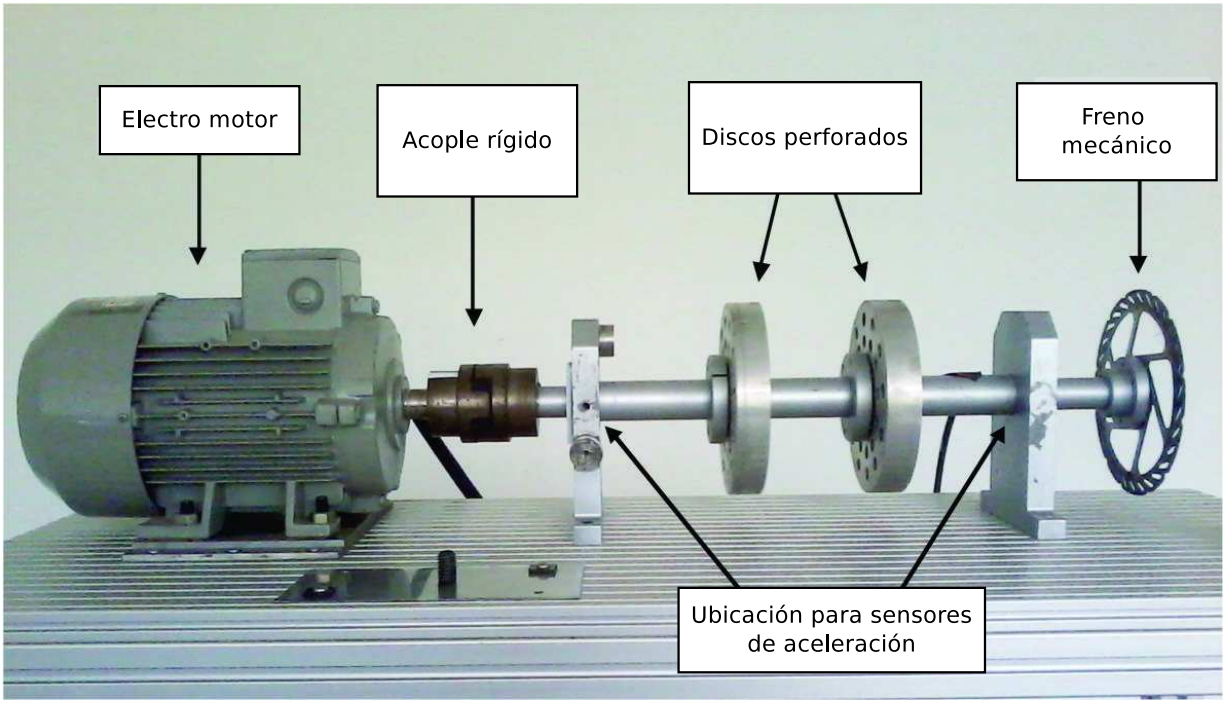

Figura 2-7.: Banco de pruebas. Insertando pesos de masa arbitraria en los discos perforados se inducen dos tipos de fallos, llamados de acuerdo con el rodamiento más próximo.

2.7.2. Bases de datos

Las bases de datos se obtuvieron a partir de grabaciones hechas en color sobre el banco de prueba durante 2 horas, funcionando el motor en condiciones de normalidad e induciendo los desbalances descritos anteriormente. Las grabaciones son descompuestas en secuencias de imágenes, generando una cada un segundo para obtener un total de 7200 imágenes por condición.

Las imágenes adquiridas son sub-muestreadas a razón de una imagen cada 60 segundos, lo que da lugar a conjuntos de 53 imágenes para cada condición de operación si se considera la segunda hora de operación del motor; este submuestreo se hace para reducir el volumen de datos a procesar. Experimentalmente se verificó que una vez transcurrida la primera hora de operación del motor, sus valores de temperatura permanecen estables.
Las imágenes obtenidas de la descomposición de las grabaciones se encuentran en el espacio de color YUV, y durante todos los experimentos, se utiliza el plano `Y` o de luminancia, para eliminar la incertidumbre que genera la necesidad de escoge una capa adecuada para los análisis. La diferencia entre una imagen en el espacio YUV tal como se obtiene de la descomposición del video en secuencias de imágenes y la que se obtiene para sólo la capa Y se muestra en la figura **2-8**. Otras especificaciones del experimento, relacionadas con el ajuste de parámetros de la cámara, se muestran en la tabla **2-1**.

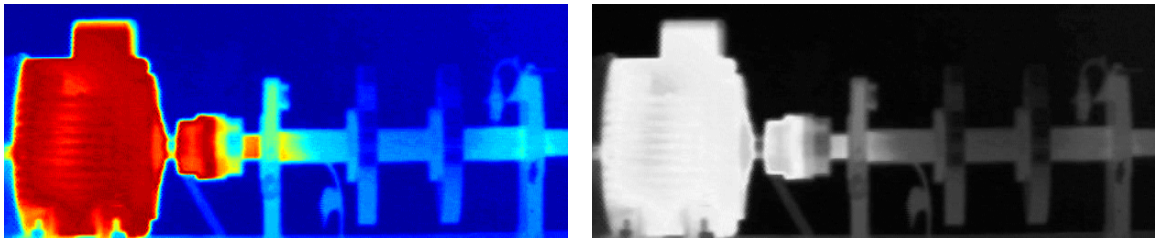

(a) Corte de la imagen original; espacio de color YUV – todas las capas.

(b) El mismo corte de la imagen de 2.8(a), mostrándose la capa Y.

Figura 2-8.: Comparación entre el mismo corte de la imagen antes y después de la extracción de la capa Y, que es la usada en el trabajo.

EL valor óptimo para la distancia entre la cámara y el objetivo puede calcularse a partir de las especificaciones sobre el campo de visión (*Field-of-View* – FOV) de la cámara, a apartir de las siguientes expresiones 2-3 y 2-4:

$$H = d\left[2\tan\left(\frac{x}{2}\right)\right] \tag{2-3}$$

$$V = d\left[2\tan\left(\frac{y}{2}\right)\right] \tag{2-4}$$

En las que H y V se refieren a las dimensiones máximas horirontal y vertical, respectivamente, que debe tener el objetivo, para ser capturado en su totalidad por la cámara a una distancia d, teniendo esta última un FOV especificado por $x \times y$

(Cámara FLIR A320)	Emisividad	0,82
	Temperatura reflejada	20°C
	Distancia al banco de pruebas	1,5m
	Humedad relativa	50 %
	Temperatura ambiente	20°C
	Escala térmica	10 – 50°C
	Resolución	320 × 240 píxeles
	Nivel espectral	7,5 a 13,0μm
	Sensibilidad térmica	50$mK@ + 30°C$
	Campo de visión	Montaje en 25° × 18,8°/0,4m
Especificaciones de video	Tamaño de las imágenes	640 × 480 píxeles
	Velocidad de muestreo	1 fps
	Formato de video	`MPEG-2`
Especificaciones, bases de datos	Adquisición video	Grabaciones de 2 horas de duración (7200s) para cada condición de operación.
	Submuestreo adicional	1 frame por cada 60s.
Especificaciones, banco de pruebas	Dimensiones	Largo: 1m (incluyendo la mesa); alto: 0,3m

Tabla 2-1.: Especificaciones de la cámara termográfica, video y de las secuencias de imágenes.

d	0.5	1	1.5	2	2.5	3	3.5	4
H	0.2217	0.4434	0.6651	0.8888	1.1085	1.3302	1.5519	1.7736
V	0.1655	0.3311	0.4966	0.6622	0.8277	0.9933	1.1588	1.3244

Tabla 2-2.: Valores de distancia (en metros) entre la cámara y el objetivo, según las especificaciones de FOV de la cámara.

2.7.3. Evaluación de las técnicas de filtrado

Para determinar si un filtrado wavelet permite una mejor representación de las imágenes, se utilizan las siguientes metodologías de filtrado: en la primera se utiliza un filtrado wavelet con los coeficientes de aproximación, y la segunda utiliza un esquema lifting. Ambos experimentos se hacen en un nivel 3 de descomposición, y utilizando como filtro wavelet el Biortogonal 3/5.

El efecto del filtrado con las metodologías consideradas puede verse en la figura **2-9**, en las que la calidad de la representación de las imágenes 2.9(b) y 2.9(c) se mide en términos de PSNR respecto a la imagen 2.9(a) de la misma figura. Para comparar los resultados obtenidos, con los del estado del arte, las pruebas se hacen sobre ROIAB.

Dado que la medida de PSNR no es consecuente con la calidad perceptual de una imagen, se consideró la medida propuesta en [44], denominada *Structural Similarity* (SSIM). La figura **2-10** muestra los valores de la medida SSIM contra en número de frames en las bases de datos, considerando las dos metodologías de filtrado citadas anteriormente.

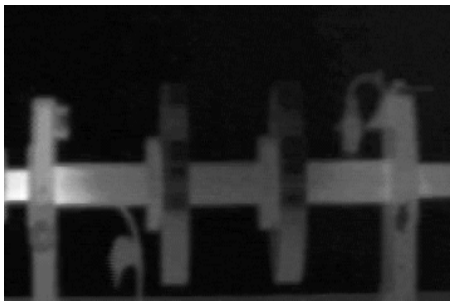

(a) Imagen original.

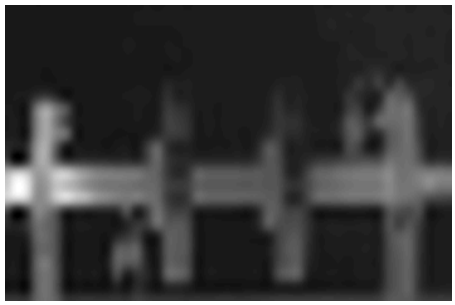

(b) Filtrado utilizando coeficientes wavelet de aproximación –filtro Biortogonal 3/5. PSNR = −6,47 dB

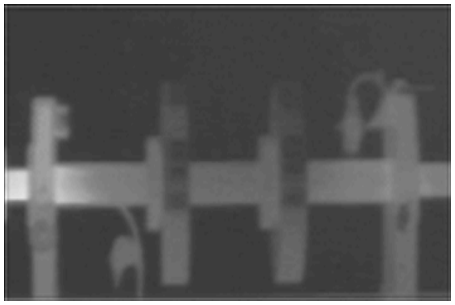

(c) Filtrado utilizando esquema lifting con lazy wavalet – filtro Biortogonal 3/5. PSNR = 0,99 dB

Figura 2-9.: Comparación - resultados visuales del filtrado wavelet de las imágenes.

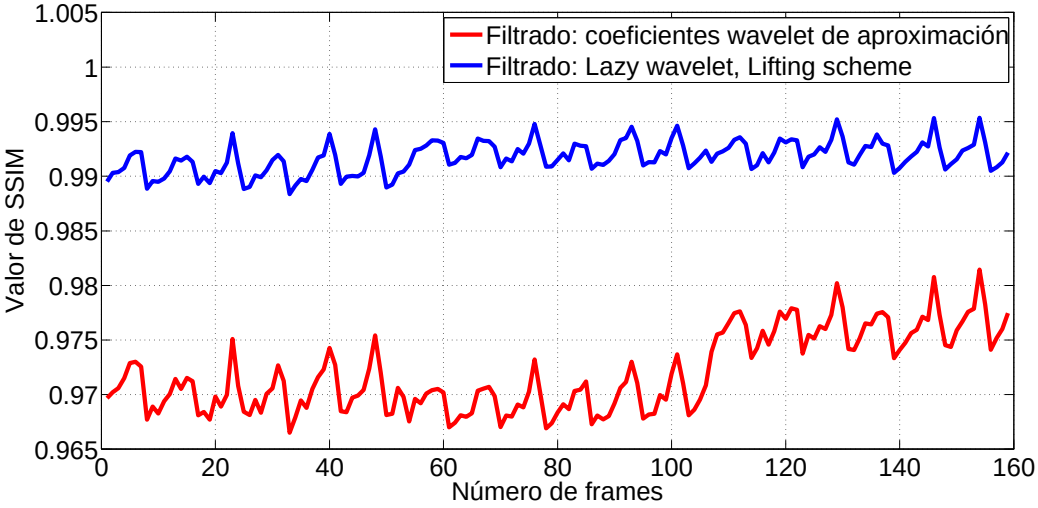

Figura 2-10.: Relación entre el valor SSIM [44] Vs número de frames para las 2 metodologías de filtrado.

2.7.4. Evaluación de la segmentación

Para la localización de los fallos, se asume que algunas variaciones en la distribución térmica de la máquina, y que son consecuencia de los fallos, se encuentran en puntos específicos de la imagen. Esto supone la necesidad de hacer una segmentación ROIs alrededor de puntos específicos donde probablemente se manifiesten estos fallos.
Una observación preliminar a las imágenes consideradas para las tres condiciones (**dpr**, **dsr** y **normal**) permite asumir que las regiones correspondientes al primer y segundo rodamiento son las que presentan mayores variaciones de temperatura, por ser estas las que están expuestas de forma directa a los efectos mecánicos que producen los desbalances en el eje del motor. Por esta razón, se selecciona previamente la ROI correspondiente, y etiquetada como ROIAB en la figura **2-11**. Así, esta ROI es la que se va a utilizar para el proceso de umbralización.
Se establece entonces como uno de los objetivos del preprocesamiento separar en las imágenes estas regiones, del fondo. El primer paso de la remoción se hizo implementando inicialmente una modificación del método de umbralización multinivel propuesto en [4], basado en la variabilidad de la distribución de probabilidad para los píxeles de una imagen. El metodo lleva a cabo umbralizaciones sucesivas de la imagen, teniendo como criterio los intervalos de tolerancia en la curva que describe el histograma de la imagen. La definición de intervalo de tolerancia, se describe en el anexo A.

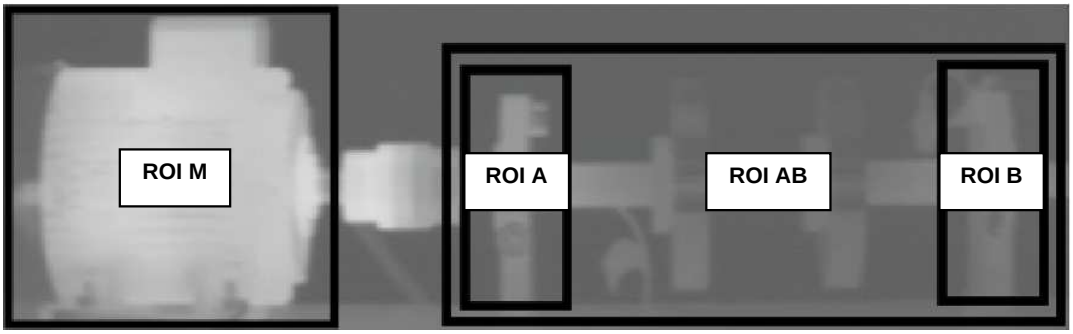

Figura 2-11.: Regiones de interés seleccionadas arbitrariamente.

2.8. Resultados

En la figura **2-12** se muestra el resultado de aplicar la metodología a una imagen arbitraria tomada de las bases de datos. En dicha figura se muestran los valores de pixel para los intervalos altos (en rojo, y bajos en negro), y cómo luego de 4 iteraciones el algoritmo genera 8 intervalos de pixel

que ahora son cuantizados de acuerdo con lo descrito en el algoritmo 2.5.2. El criterio de parada produce un número reducido de iteraciones que no producen el traslape de los intervalos, y con los que se cubre prácticamente todo el rango de valores posibles que contiene la imagen. Puede verse también que tal como se asumió con anterioridad, hay una mayor variación para ciertos valores de píxeles en los intervalos de valores altos, por lo que se presume que una umbralización global de la imagen basada en el primer intervalo de valores altos, y asignando a los píxeles en éste intervalo el valor de 255 y al resto 0, segmenta una parte considerable de las ROIs que se buscan, vistas como *hot-spots* presentes en la imagen. Se presume que los píxeles en los 4 intervalos de valores bajos contienen áreas de la imagen pertenecientes al fondo.

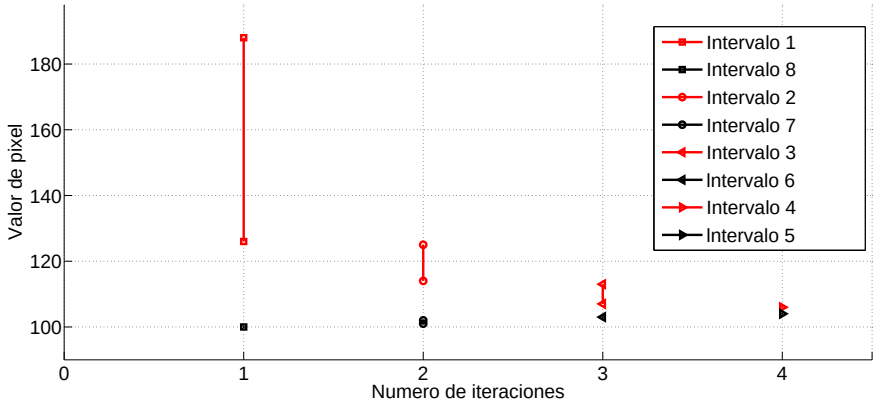

Figura 2-12.: Intervalos de píxeles que son cuantizados, luego de aplicar a una imagen la metodología de umbralización multinivel propuesta.

Los resultados de la umbralización se ilustran en la figura **2-13**. La imagen final se binariza teniendo en cuenta el rango en que se encuentran los valores más altos de pixel, con lo que resulta una “máscara” que filtra las ROIs de la región de los dos discos perforados y del fondo.
Los resultados sobre la regularidad en los intervalos que produce la metodología de umbralización multinivel propuesta se ven en la figura **2-14**, donde se presenta la regularidad que se requiere para los intervalos obtenidos con un mismo valor de k para todas las clases. Las líneas verticales indican el rango de valores cubiertos por cada intervalo.
El parámetro k tiene además implicaciones respecto al número de iteraciones que hace el algoritmo, de modo que debe verificarse cuál valor produce un menor número de iteraciones. Esto se hizo implementando el algoritmo con valores de k entre 1 y 3. para 3 imágenes arbitrarias, una para cada condición, en el mismo instante de tiempo, en las 3 condiciones de operación, y observando el número de iteraciones que resulta para cada valor de k.

Un valor de k mayor produce un mayor número de iteraciones puede deberse a que el histograma de esta ROI tiene muy poca variación en los valores medios y bajos, y por lo tanto valores de σ muy pequeños, que generan una gran cantidad de intervalos con rangos de un pixel (por ejemplo [123 123]). Es posible inferir que no ocurre lo mismo con el extremo derecho de los histogramas

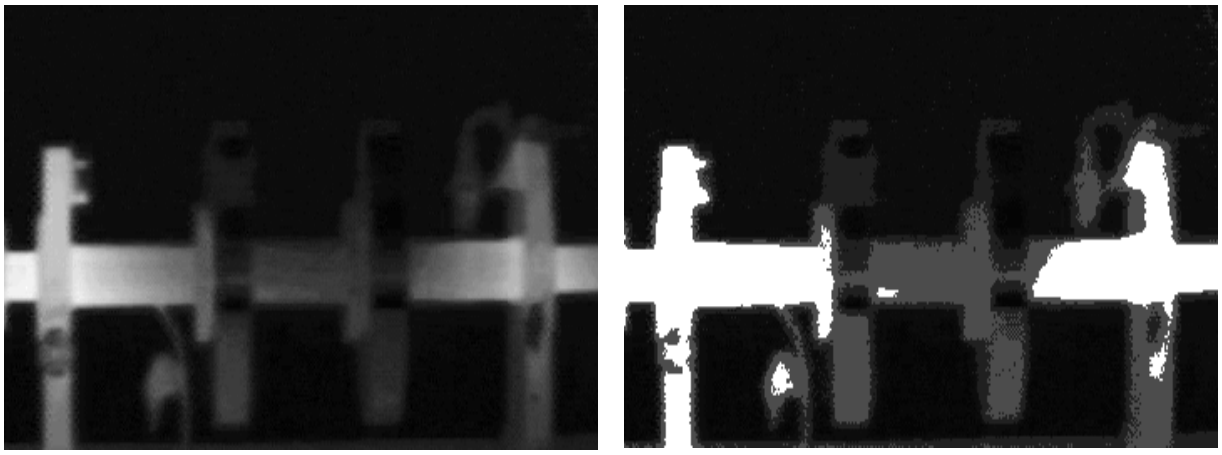

(a) ROIAB antes de la cuantización. (b) ROIAB después de la cuantización.

Figura 2-13.: Comparación entre la imagen original, para el corte de sobre ROIAB, y la imagen cuantizada luego de hacer la umbralización multinivel. El intervalo con los valores altos tras la cuantización se utiliza para binarizar la imagen.

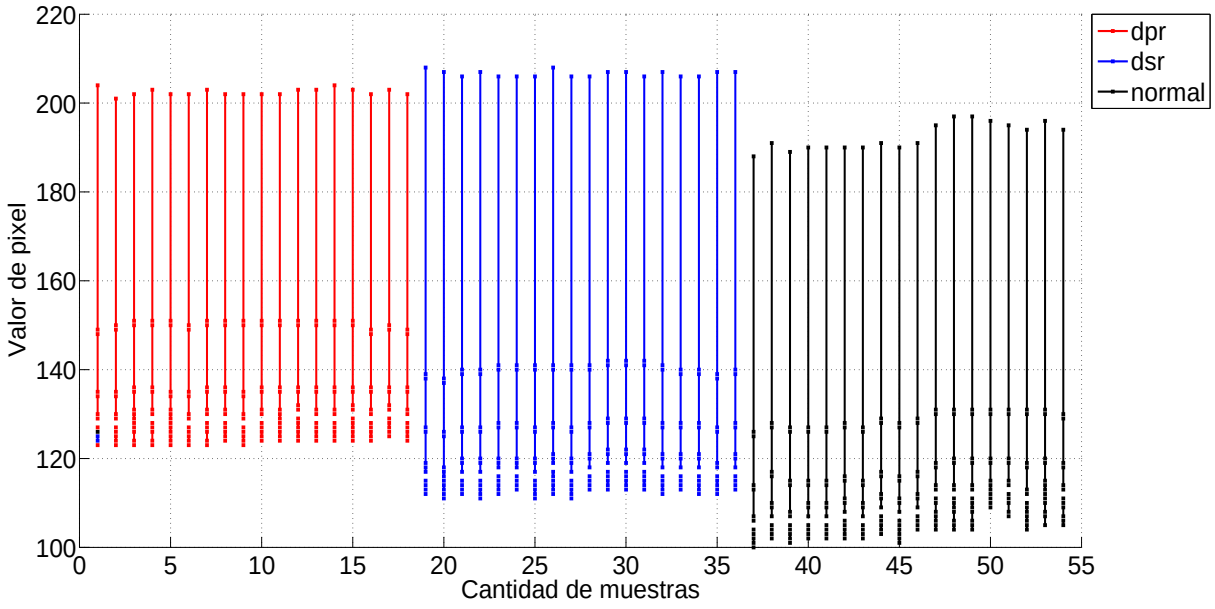

Figura 2-14.: Intervalos que genera el algoritmo de umbralización multinivel propuesto para $k = 1$, utilizando un conjunto reducido del total de las bases de datos para todas las condiciones.

de las imágenes y por eso hay unos pocos intervalos que contienen la mayor variación de píxeles en las imágenes. De acuerdo con la hipótesis lanzada previamente, los píxeles que están en estos intervalos contienen las ROIs que se requiere segmentar.

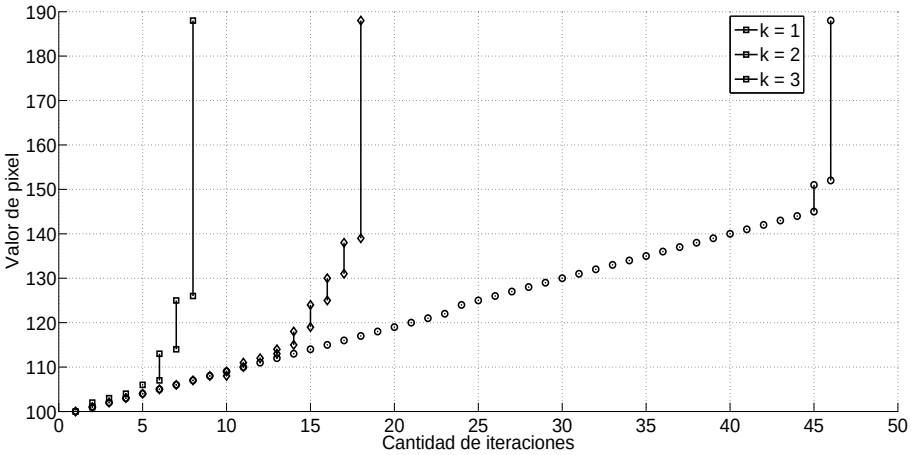

Figura 2-15.: Intervalos que genera el algoritmo de umbralización multinivel propuesto para diferentes valores de k, utilizando una imagen arbitraria del banco de pruebas.

A partir de las figuras **2-14** y **2-15** se ve que es posible utilizar el mismo k para todo el conjunto de las imágenes. Dado que las mayores variaciones de pixel, y consecuentemente de temperatura, se presentan para la condición **dpr**, se utiliza una imagen de esta condición, se le aplica la cuantización y los píxeles que se encuentran dentro del primer subintervalo se utilizan para umbralizar la imagen. Adicionalmente, para suprimir algunas ROIs *falsas* que resultan de la transformada, se hizo los siguiente:

- Se cuantiza la imagen utilizando la umbralización multinivel propuesta en el algoritmo 2.5.2, teniendo en cuenta el intervalo con valores más altos de pixel que resultan en la umbralización (ver 2.13(b)). Luego, se hace una apertura de la imagen, y se eliminan elementos conexos con menos de 200 píxeles. El resultado de esto se muestra en la figura 2.16(c). Los píxeles en estas máscaras se utilizan como marcadores para la segmentación watershed.

- Se implementa la transformada watershed, y se comparan los píxeles de cada una de las regiones watershed con los píxeles de estas mismas regiones en las máscaras de la imagen umbralizada y se calcula la moda de los píxeles en la región para la imagen umbralizada. Si la moda es cero, entonces la región watershed en la imagen segmentada toma el valor de cero. Esto elimina algunas las regiones *falsas* que se ven al comparar la imagen 2.16(d) con la 2.16(e). Las ROIs resultantes se etiquetan (2.16(f)) y para cada una de éstas se hacen los procedimientos de análisis posteriores.

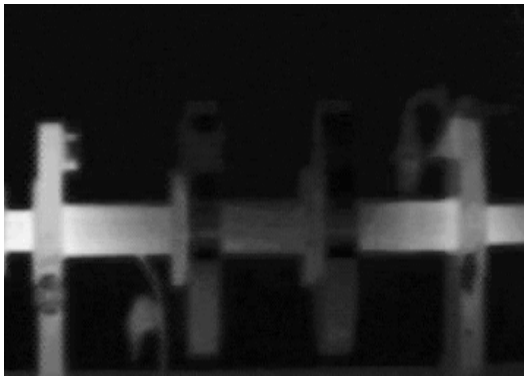

(a) ROIAB antes de la cuantización.

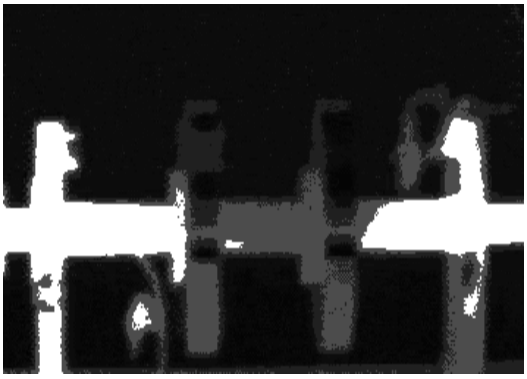

(b) Imagen cuantizada.

(c) Máscaras para las ROIs (en blanco) tras la cuantización.

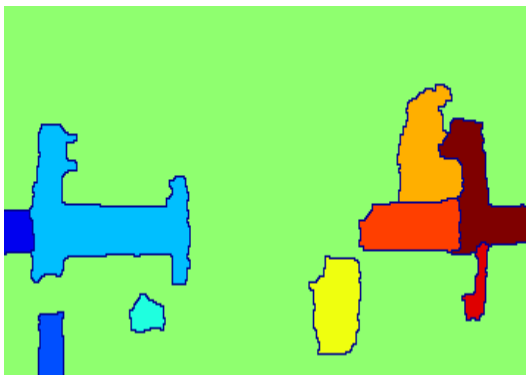

(d) Segmentación watershed inicial.

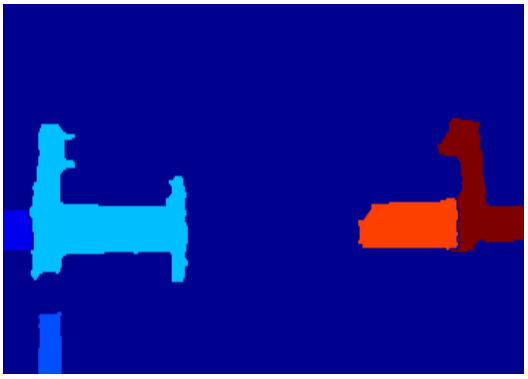

(e) Máscaras definitivas para las ROIs.

(f) ROIs detectadas después del preprocesamiento.

Figura 2-16.: Resultado de la umbralizacin multinivel, con la consecuente identificacin de ROI relacionadas con puntos de calor.

2.9. Conclusiones

Los resultados de las pruebas muestran que el corte que contiene a ROIAB permite discriminar entre los fallos, y que en algunos casos no se requiere de esquema de preprocesamiento alguno. Sin embargo, la posibilidad de utilizar una ROI en lugar de todo un corte de la imagen supone una gran ventaja en términos de tiempo de cómputo y en la precisión de la identificación. Por otra parte, es notable que sea posible discriminar las condiciones de operación de la máquina, considerando una ROI que comparada con el conjunto total de la imagen es considerablemente pequeña, como es el caso de ROIA.

Parte de la conveniencia de utilizar un filtrado wavelet, tiene que ver con que la etapa siguiente utiliza una transformada que es bastante sensible a los mínimos locales en la imagen. Los resultados dependen de la aplicación; las representaciones que ofrece el filtrado conducen a resultados diferentes si por ejemplo se utilizan como etapas previas a la segmentación watershed.

Los resultados de la binarización de las imágenes, muestran que la metodología de umbralización propuesta tiene un desempeño bastante aceptable, permitiendo segmentar un contorno global de ROIAB muy similar al detectado por la transformada watershed. Esto se debe a que los píxeles en las ROIs presentan una mayor variabilidad de intensidades que las regiones correspondientes al fondo de la imagen.

Como trabajo futuro se considera el análisis de la denominada ROIM, la cual es la región que cubre al motor. Nótese que en la figura **2-8**, el efecto térmico de que produce el desbalance afecta la distribución térmica del motor. Por consiguiente, algunos fallos pueden identificarse dentro de esta región. El desafío consiste en la cantidad de piezas que involucran el motor,haciendo difícil su segmentación.

3. Extracción de características

3.1. Aspectos preliminares

En este capítulo se analizan dos tipos de características utilizadas para la detección de fallos en máquinas rotativas: las medidas estadísticas y los gradientes. Las primeras son las propuestas en [48] y en [9], y se refieren a valores de pixel en las imágenes. Una razón para considerar el uso de este tipo de medidas es que, en el caso de las imágenes termográficas, el color de un pixel, o su nivel de gris se relaciona directamente con la temperatura que irradia un objeto hacia una cámara térmica. El otro tipo de características se refiere a direcciones de propagación de calor en las imágenes, vistas como gradientes de temperatura. Este último tipo de características se utiliza para capturar información sobre cambios en la distribución de probabilidad de las direcciones en las que se presentan gradientes de temperatura. Los resultados de este enfoque son independientes si la distribución de probabilidad de los datos es paramétrica o no, y los datos tienen una clara interpretabilidad ya que nuevos puntos de calor que irradian energía hacia las mismas o hacia nuevas direcciones en las imágenes en condiciones normales de operación, permiten la discriminación de patrones térmicos diferentes a los normales.
El capítulo está organizado como sigue: En la sección 3.2 se describen las medidas estadísticas, con las que se cuantifica información sobre las distribuciones de probabilidad de los píxeles en la imagen; en la sección 3.3 se describen las carácterísticas direccionales, que capturan información sobre ángulos de propagación de calor en las ROIs; en la sección 3.4 se presentan algunos conceptos sobre relevancia que se utilizan para reducir las dimensiones de los conjuntos de características direccionales y para evaluar la pertinencia de las características estadísticas; en la sección 3.5 se describen los experimentos que se hacen para obtener la caracterización de las imágenes y de las ROIs descritas en el capítulo 2; en la sección 3.6 se muestran los resultados obtenidos y finalmente en la sección 3.7 se presentan las conclusiones de los análisis hechos.

3.2. Características estadísticas

El histograma de una imagen en escala de grises representa una aproximación a la función de densidad de probabilidad de sus niveles de gris [43]. El histograma por si solo no brinda ningún acercamiento preciso hacia la localización espacial de fallos, pues solo presenta información global sobre la imagen [20]. Siguiendo los experimentos descritos en [48] para el mismo propósito de identificación de fallos, se calculan los coeficientes wavelet de aproximación de las imágenes,

utilizando el filtro wavelet Biortogonal 3/5, y se calculan 7 medidas estadísticas, las cuales pueden ser categorizadas como sigue:

- *Medidas de tendencia central* – Son medidas que permiten la identificación de la distribución de los datos, de acuerdo a la localización de su posición central [10]. Pertenencen a este tipo de medidas el Valor Medio de los datos μ, y el Centroide de la curva del histograma, propuesto en [9]. Se incluye también la Entropía, dado que está definida como el valor esperado de la probabilidad de un logaritmo. Debe notarse que el centroide es una función de la curva que describe un histograma, y por lo tanto depende de la distribución de los datos en bins. El ancho debe ajustarse de modo que el centroide permita la identificación óptima de fallos.

- *Medidas de dispersión estadística* – Son indicadores de la dispersión de los datos respecto a parámetros que suelen ser medidas de tendencia central, como la media [10]. Se incluyen en esta categoría a la desviación estándar (σ) y la desviación media absoluta (MAD) de los datos.

- *Medidas de forma* – Caracterizan la geometría de la distribución de los datos, y a éste tipo de medida pertenecen la asimetría y la curtosis. La primera es una medida de simetría horizontal con respecto a una distribución normal, indicando la dirección de la cola de la distribución; la segunda es una medida de su apuntamiento, es decir, de que tan concentrados están los datos en el centro de la distribución [8].

Hay algunas limitaciones con las medidas estadísticas propuestas en [48], y se refieren principalmente a que parámetros como μ y σ se determinan asignando el mismo peso en el conjunto de los datos. Esto los hace muy sensibles a la presencia de valores atípicos. Entonces, estimadores como la asimetría y la curtosis, al estar definidas en términos de distribuciones de probabilidad paramétricas, pueden presentar una alta variabilidad cuando los datos no son gaussianos [7]. Una solución, propuesta en [9], fue considerar la media ponderada de los datos, pues en este caso hay una ponderación diferente para los píxeles. Este estimador tiene la vantaja de que es independiente de si la distribución de probabilidad de los píxeles es paramétrica o no lo es.

3.3. Características direccionales

Si la propagación de calor en una imagen termográfica se hace de forma isotrópica y de forma perpendicular a la línea de visión de la cámara, entonces se puede analizar la imagen con un operador de gradientes isotrópico. Por ejemplo, una ventana Gaussiana para estimar la probabilidad de que una región en la imagen sospechosa de ser una ROI efectivamente lo sea [32]. Si la propagación de calor es anisotrópica, entonces una hipótesis razonable es que un operador

anisotrópico permita obtener información sobre el valor y la dirección en la cual se propaga el calor. Por lo tanto, para este experimento se consideran los operadores de gradiente Sobel (ecuación 3-1) y de Prewitt (ecuación 3-2), para estimar cambios en la propagación (magnitud y dirección) de calor en las imágenes. Una ilustración de la presencia de esta característica en la imagen térmica se ilustra en la figura **3-1**.

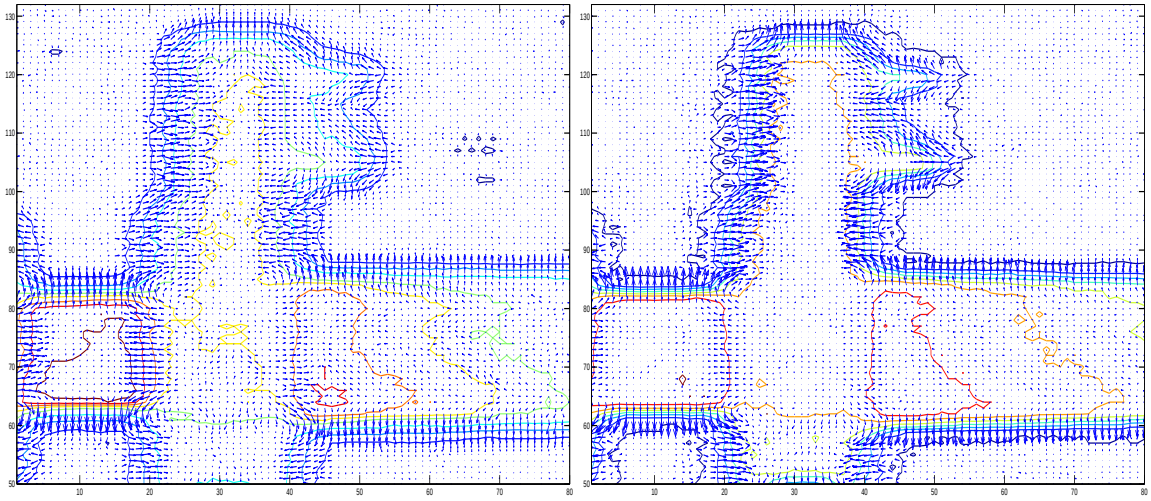

(a) **normal** (b) **dpr**

Figura 3-1.: Comparación del campo de gradiente field para la misma región de la imagen, bajo dos condiciones de operación diferentes.

La obtención de información direccional, se hace haciendo la convolución de la imagen, con los operadores descritos. Formalmente, las operaciones son las siguientes:

Sea **X** la porción de la imagen acotada por ROIAB. Los operadores direccionales se definen como:

$$T_x = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix}; \quad T_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ +1 & +2 & +1 \end{bmatrix} \tag{3-1}$$

$$T_y = \begin{bmatrix} -1 & 0 & +1 \\ -1 & 0 & +1 \\ -1 & 0 & +1 \end{bmatrix}; \quad T_y = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ +1 & +1 & +1 \end{bmatrix} \tag{3-2}$$

Así, las componentes horizontal G_x y vertical G_y de la dirección del gradiente para cada pixel de la imagen se calculan mediante la convolución de los operadores de gradiente y la imagen:

$$G_x = T_x * \mathbf{X} \tag{3-3}$$

$$G_y = T_y * \mathbf{X} \tag{3-4}$$

Por último, la magnitud y la dirección del gradiente se realizan mediante las expresiones 3-5 y 3-6 respectivamente:

$$|G|(x,y) = \sqrt{{G_x}^2 + {G_y}^2} \tag{3-5}$$

$$\alpha(x,y) = tan^{-1}\left(\frac{G_y}{G_x}\right) \tag{3-6}$$

donde $|G|$ y α son las componentes de magnitud y dirección del gradiente, respectivamente.

Para determinar los valores de fase α relevantes para la identificación de fallos, se realiza un análisis de características relevantes sobre el histograma de direcciones de gradiente (HDG), o de bordes (*Edge Direction Histogram*) [12]. El HDG se determina como sigue: 1.) para cada punto (pixel) se extrae la dirección del gradiente utilizando la Ecuación (3-6), usando tanto el operador Prewitt como el Sobel, descritos por las Ecuaciones 3-1 y 3-2 respectivamente; 2.) Cada dirección es almacenada y discretizada en el vector $\vec{p} = \{G_x, G_y\} \in N$, en la que a cada dirección le corresponde a un bin en el histograma; 3.) se utiliza Análisis de Componentes Principales (PCA) para encontrar las direcciones relevantes. Este análisis se realiza por separado para cada imagen segmentada, comparando la información entre imágenes con patrones térmicos normales y de fallo. Luego, se puede no solo identificar la presencia de una patrón anormal (un fallo), sino también asignarle una localización espacial.

3.4. Análisis de relevancia

El análisis de relevancia se utiliza para distinguir variables que efectivamente representen un fenómeno de acuerdo a una medida de evaluación, denominada *relevancia*. Del mismo modo, distingue las características menos representativas, que reciben el nombre de *características irrelevantes*. Sea $\boldsymbol{X_\xi} \in \mathbb{R}^{N\times p}$ un conjunto de objetos de N muestras que son descritos por un conjunto p-dimensional de caraterísticas: $\boldsymbol{\xi} = \{\xi_i : i = 1, \ldots, p\}$. Además, cada muestra está asociada a una única etiqueta de clase $\boldsymbol{c} = \{c_k \in \mathbb{N} : k = 1, \ldots, K, \}$, donde K es la cantidad de clases considerados. Entonces, dado $\boldsymbol{X_\xi}$, y para cada una de las características $\xi_i \in \boldsymbol{\xi}$, la función de relevancia g se define a continuación:

$$\begin{aligned} g &: \mathbb{R}^{N\times p} \times \boldsymbol{\xi} \to \mathbb{R} \\ (\boldsymbol{X_\xi}, \xi_i) &\mapsto g(\boldsymbol{X_\xi}, \xi_i) \in \mathbb{R} \end{aligned} \tag{3-7}$$

donde sobre la función de relevancia introducida, se determinan las siguientes características:

- *No negatividad*, es decir, $g(\boldsymbol{X_\xi}, \xi_i) \geq 0, \ \forall i$.
- *Nulidad*, la función $g(\boldsymbol{X_\xi}, \xi_i)$ es nula si la características ξ_i no tiene relevancia en absoluto.

– *No redundancia*, if $\xi_i = \alpha\xi_j + \eta$, donde el evaluado real $\alpha \neq 0$ y η es un ruido con $\mu = 0$ y $\sigma = 1$, entonces, $|g(\boldsymbol{X}_{\boldsymbol{\xi}}, \xi_i) - g(\boldsymbol{X}_{\boldsymbol{\xi}}, \xi_j)| \to 0$.

La evaluación de $g(\boldsymbol{X}_{\boldsymbol{\xi}}, \xi_i)$ se denomina *peso de relevancia*. Se asume que el mayor peso está asociado con la característica más relevante, de modo que el ordenamiento de los pesos de acuerdo a su relevancia produce el arreglo:

$$\boldsymbol{g}(\boldsymbol{X}_{\widehat{\boldsymbol{\xi}}}, \boldsymbol{\xi}) = [g_1 \cdots |g_i| \cdots |g_p]^\top \in \mathbb{R}^p, con \quad g_i \geq g_{i+1} \tag{3-8}$$

En este estudio se ordenan los pesos de relevancia, para determinar cuales características direccionales contribuyen a la discriminación de las clases analizadas.

3.5. Marco experimental

Para las medidas estadísticas se hace un análisis de conglomerados. Para las medidas direccionales se hacen pruebas de relevancia, basadas en análisis de componentes principales (*Principal Component Analysis* – PCA). Se comparan los resultados de evaluar la ROI propuesta en [48] con las propuestas en el capítulo 2, para establecer la pertinencia de enfocar los análisis hacia las ROIs. El marco experimental se describe gráficamente en la figura **3-2**

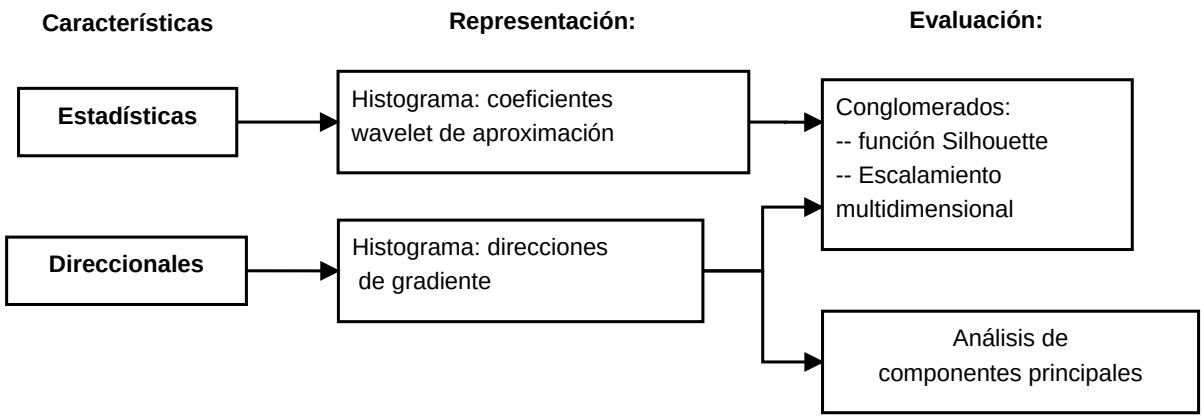

Figura 3-2.: Marco experimental de capítulo.

3.5.1. Selección óptima del ancho de bin en el histograma para el cálculo del centroide

La curva que describe un histograma varía con el ancho de los bins. Un ancho de bin pequeño produce una curva con picos espúreos que dificultan el análisis paramétrico del histograma. Por el

contrario, un ancho de bin muy grande produce una representación pobre de los datos que puede incluso exhibir una parametrización artificial por el solapamiento de información relevante en los datos. Por esta razón, para determinar cual es el ancho óptimo de los bins para los histogramas de coeficientes wavelet de aproximación de cada ROI, se consideraron los siguientes enfoques:
Primero, bins de ancho uno, es decir, tantos bins, como datos diferentes hay en el histograma; segundo, seleccionar un número de bins igual a la raíz cuadrada del número de datos a representar, tercero, el método propuesto por Sturges [40], de seleccionar $k = [log2n + 1]$ bins; cuarto, el método propuesto en [38], en el cual se propone un ancho óptimo para el ancho de los bins, basado en la minimización de una función estimada de riesgo. Para validar la calidad de la representación, se utiliza la función *Silhouette* para medir el grado de separación en las clases, considerando los esquemas de asignación de ancho de bins descritos anteriormente.

3.5.2. Análisis de conglomerados

Siendo i un objeto perteneciente al cluster C_k, por ejemplo una imagen etiquetada como **dpr** y perteneciente a un cluster del mismo nombre, la disimilitud promedio de i a los otros objetos C_k se define como $c_k(i)$. Por otra parte, en el cluster C_m, la disimilitud promedio de la muestra i a las muestras pertenecientes a todos los objetos C_m se define como $dis(i, C_m)$, donde $C_m \neq C_k$. Luego de seleccionar $C_m(i) = \text{mín}\{dis(i, C_m)\}$, $C_m \neq C_k$, se obtiene una medida de disimilitud entre i y su cluster vecino, y se describe mediante la función *Silhouette*, como sigue:

$$silh(i) = \frac{C_k(i) - C_m(i)}{\text{máx}\{C_k(i), C_m(i)\}} \tag{3-9}$$

donde $silh(i) \in \mathbb{R}\ [-1, 1]$.
La ecuación 3-9 representa una medida de similitud, en la que se utiliza la distancia *cityblock* para determinar la función *silhouette*. Por ejemplo, un valor de $silh(i)$ cercano a 1, indica que hay clusters compactos para las muestras de la misma etiqueta, y una clara separación entre clusters de diferentes etiquetas. Por otra parte, valores de $silh(i)$ cercanos a -1, indica el traslape de clusters de diferentes etiquetas. Finalmente, una medida de la calidad de la separación entre los clusters (clases) se obtienen promediando los valores de la función *silhouette* sobre el conjunto de puntos para cada cluster.
Para verificar la pertinencia de las medidas consideradas, se utilizaron dos metodologías de identificación:

- *identificación generalizada de fallo* – IGF, con la cual se busca identificar el fallo independientemente de su localización. Para este caso, las 106 imágenes que pertenecen a las clases **dpr** y **dsr** se etiquetan como **fallo** y las 53 restantes se etiquetan como **normal**. Se consideraron 4 ROIs, y se calculó el promedio de la función *silhouette* utilizando una sola característica a la vez.

- *identificación localizada de fallo* – ILF, con la que se busca identificar el fallo, y su localización. En esta caso caso se consideran las 3 clases descritas en el capítulo 2, lo que da lugar a 53 muestras estiquetadas como **dpr**, 53 como **dsr** y 53 como **normal**.

En los experimentos en los que se trabaja la identificación de fallos, se utiliza la metodología IGF; en los que se trabaja la localización, se consideran las 3 clases y se utiliza ILF.

3.5.3. Análisis de relevancia

Anteriormente se lanzó la hipótesis de que la presencia de fallos en la máquina bajo prueba se ve reflejada en cambios en la distribución de probabilidad de los ángulos de gradiente. El análisis de PCA se hace con el objetivo de evaluar la relevancia de los ángulos calculados en las imágenes. El análisis de relevancia se utiliza para las medidas direccionales, por tratarse de un problema de mayor dimensión. Las pruebas consistieron en obtener los pesos de relevancia del conjunto de las 360 características, es decir, los ángulos de gradiente descritos por la expresión 3-6.

3.6. Resultados

3.6.1. Resultados para el cálculo del ancho óptimo de bins

Enfoque	**ROI**			**Promedio**
	ROI1	ROI2	ROIAB	
Bins de ancho 1	0.9898	0.9848	0.9895	0.9847
Square-root choice	0.9936	0.9833	0.9889	0.9886
Método de Sturge $k = [log_2 n + 1]$ [40]	0.8685	0.9632	0.9182	0.9166
Método de Shimazaki & Shinomoto [38]	0.9893	0.9852	0.9898	0.9881

Tabla 3-1.: Valores medios de la función *Silhouette* para el cálculo del centroide.

En la tabla **3-1** puede verse que la regla de la raíz cuadrada es el enfoque óptimo para el cálculo del ancho de los bins en los histogramas. Aunque se obtienen resultados comparables al utilizar el método propuesto en [38], el cálculo del número de bins requiere de un mayor tiempo de cómputo, de modo que por simplicidad, se optó por la regla de la raíz cuadrada.

3.6.2. Análisis de conglomerados para las características estadísticas

Estas pruebas involucraron un análisis de la metodología propuesta en [48]. A partir de los coeficientes wavelet de aproximación se generan histogramas, y sobre estos se calculan las 7 medidas estadísticas descritas anteriormente. Los resultados se obtienen de medir el valor promedio de la función *silhouette* para las 7 medidas, utilizando una a la vez. Se utilizó el

filtro wavelet para obtener los coeficientes de aproximanción en el nivel 3 de descomposición sobre ROIAB. No se consideró la remoción del fondo de las imágenes, y se tuvieron en cuenta las tres clases: **dpr**, **dsr** y **normal**. Los resultados muestran que para el caso de las tres clases consideradas, las medidas de forma no son suficientemente discriminantes y como resultado los valores promedio de la función *silhouette* son negativos, indicando el traslape de grupos de clase diferente. Finalmente, en la tabla **3-3** se muestra el resultado de aplicar PCA a las caractetrísticas estadśiticas, utilizando la regla de la raíz cuadrada para calcular el número de bins en los histogramas.

Medida	**ROI**	$\overline{silh}$	
		IGF	ILF
Media	ROI1	0.9889	0.5426
	ROI2	0.9848	0.4031
	ROIAB	0.9895	0.3607
Desviación Estándar	ROI1	0.8417	0.7888
	ROI2	0.9176	0.8306
	ROIAB	0.9654	0.5719
Asimetría	ROI1	0.8195	0.3892
	ROI2	-0.0699	-0.0866
	ROIAB	0.9722	0.3777
Curtosis	ROI1	0.8484	0.3808
	ROI2	-0.0654	0.0217
	ROIAB	0.9777	0.3625
DMA	ROI1	0.8523	0.7708
	ROI2	0.9011	0.8292
	ROIAB	0.9730	0.5140
Entropía	ROI1	-0.0043	-0.0898
	ROI2	0.0322	-0.0045
	ROIAB	0.3518	0.3205
Centroide	ROI1	0.9936	0.4167
	ROI2	0.9833	0.3787
	ROIAB	0.9889	0.3717

Tabla 3-2.: Valores promedio de la función $silh(i)$.

3.6.3. Análisis de relevancia para las características direccionales

En la figura **3-3** se ven los pesos de relevancia que arroja el análisis de PCA. A partir de esta figura se infiere que un número reducido de características contienen la mayor variabilidad de los datos,

Preproceso	Índices - pesos de relevancia	Variación – PSNR
Ninguno	$3, 4, 7, 1, 2, 6, 5$	
Filtrado Biortogonal 3/5	$3, 4, 6, 1, 2, 5, 7$	17,25 ± 2,48
LS Lazy wavelet Biortogonal 3/5	$3, 4, 6, 1, 2, 5, 7$	15,28 ± 2,57

Tabla 3-3.: Pesos de relevancia para las características estadísticas para ROIAB.

y que se pueden utilizar estas características para clasificar correctamente los fallos.

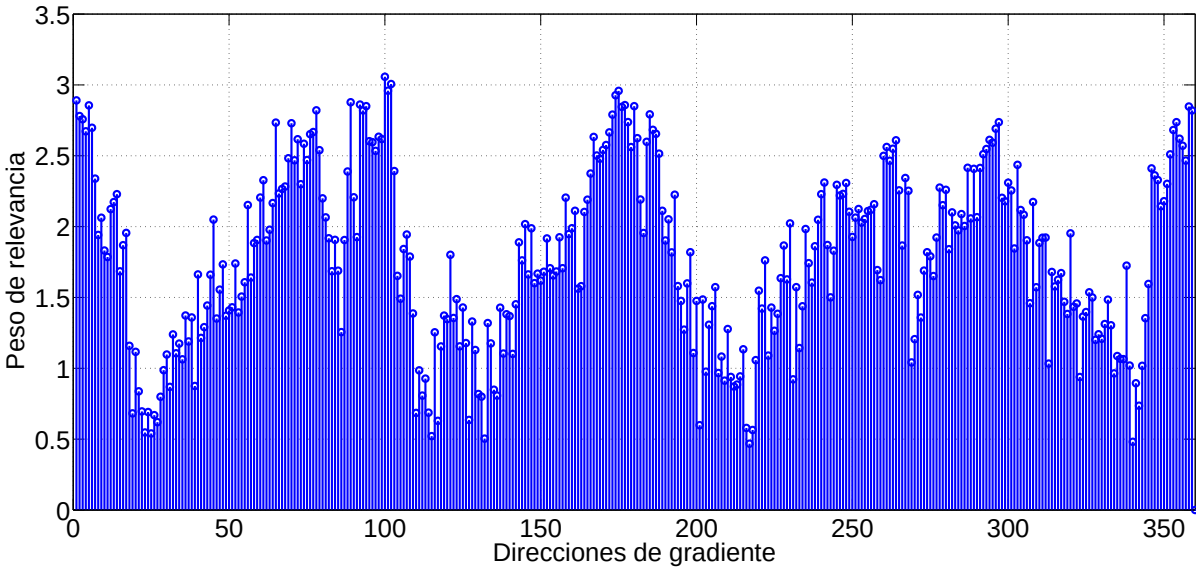

Figura 3-3.: Pesos de relevancia para el total de las 360 direcciones de gradiente.

3.7. Conclusiones

- La umbralización de la imagen produce una cuantificación que permitiría prescindir de la necesidad de cambiar el ancho óptimo de bin para el caso de los histogramas de coeficientes wavelet de aproximacíon. Esto se debe a que la discretización de la imagen reduce el número de bins que tiene su histograma. Sin embargo, esta discretización se hace con otro propósito y es el de identificar regiones con propiedades similares en términos de temperatura. En tal sentido, el error que se produce en la imagen una vez umbralizada, se compensa por la posibilidad de localizar el fallo.

- A partir de los resultados de la tabla **3-2** puede concluirse que tienen una mayor consistencia las medidas de tendencia central y de dispersión respecto a las de forma. Esto es una consecuencia de que las medidas de forma están definidas en términos de distribuciones de

probabilidad paramétricas, y cuando este no es el caso, el cálculo de medidas de dispersión y de tendencia central, particularmente la media ponderada, sigue teniendo un significado válido.

- Para el caso de los histogramas de coeficientes wavelet de aproximación, es posible disminuir el tiempo de cómputo a partir de la modificación de criterio para el ancho de bin, sin perder la precisión de la representación.

- Se encontró que los ángulos más relevantes para la identificación del fallo en máquinas rotativas, especificamente para la detección de condiciones de desbalance, se agrupan en valores cercanos a 90 grados. Por esta razón los ángulos cercanos a los relevantes tienen pesos de relavancia similares. Esto indica que estos pesos son altamente correlacionados entre sí, por lo que se sugiere que las características se relacionen con grupos de ángulos, de acuerdo con la cercanía a los ángulos más relevantes.

4. Clasificación de fallos

4.1. Aspectos preliminares

El objetivo principal de este capítulo es mostrar la discriminancia de las características descritas en los capítulo 3, orientadas a la identificación de fallos en máquinas rotativas. Se considera el desempeño de las características tanto para ROIAB como para las ROIs segmentadas mediante transformada watershed. Para ambas se mide el desempeño de las características estadísticas y las de ángulos de gradiente descritos en el Capítulo 2. Dado que el principal interés con la segmentación de las ROIs es encontrar en las piezas de la máquina evidencia sobre donde se manifiestan los fallos, se considera la metodología ILF descrita en la sección 3.5, es decir, las tres clases.

El capítulo está organizado como sigue: en la sección 4.2 se describe la metodología previa a las pruebas de validación que involucran PCA; en la sección 4.4 se decribe el marco experimental de las pruebas; en la sección 4.5 se presentan los resultados de los experimentos para todas las características, y en la sección 4.6 se comparan los resultados de las pruebas de clasificación para la ROI descrita en [48] y las que resultaron de la segmentación watershed en el capítulo.

4.2. Análisis de PCA y selección de características

En esta etapa los datos tienen una representación en la forma de vectores de características. Para el caso de las direcciones de gradiente, la información ha sido discretizada asignando un ancho de uno, para los bins en los histogramas. Sin embargo, en el capítulo 3 se concluyó que no todas las características tienen la misma relevancia, de modo que debe seleccionarse un subconjunto de características que permita reducir la dimensión del problema sin perder capacidad de generalización. Esto se hace seleccionando aquellas que mejor representan la variabilidad del fenómeno bajo análisis (aumentos de temperatura y su dirección). Luego del análisis de PCA para obtener los pesos de relevancia de las características, se ordenan y se hacen pruebas de clasificación hasta ver que el error de clasificación permanezca estable. En la figura **3-3** se ven pesos de relevancia para ROIAB. Los picos en los que se concentran los mayores pesos de relevancia, corresponden a las características más relevantes. Para cada ROI, el número de características que se utiliza para la clasificación final está basado en la curva de error de clasificación.

4.3. Escalamiento multidimensional

El escalamiento mulitidimensional (*multidimensional scaling* – MDS) se refiere al conjunto de métodos que se utilizan para obtener representaciones sobre la disimilitud de conjuntos de datos a partir del análisis de matrices de disimilitud. Los métodos del escalamiento multidimensional buscan proyecciones lineales o no lineales, que representen las relaciones de los datos reduciendo la dimensión de estos a un conjunto lo suficientemente pequeño para permitir la inspección visual de los datos [42].
Si la distancia entre un objeto x_i y x_l se representa mediante $d(k,l)$, y la distancia en un espacio de bidimensional, entre x'_i y x'_l por $d'(k,l)$, entonces el objetivo del MDS es optimizar la representación de modo que las distancias entre los objetos en el espacio bidimensional se tan cercana como se posible a las distancias en el espacio original [42]. La optimización se hace minimizanado funciones objetivos que, si se basan en métricas euclidianas, tienen la forma:

$$E = \sum_{k \neq l} \left[d(k,l) - d'(k,l) \right]^2 \tag{4-1}$$

Si no es posible una reproducción de las distancias euclidianas, entonces se utiliza la siguiente función, o modificaciones de esta:

$$E = \frac{1}{\sum_{k \neq l} \left[d'(k,l) \right]^2} \sum_{k \neq l} \left[f(d(k,l)) - d'(k,l) \right]^2 \tag{4-2}$$

en las que para cualquier configuración de los puntos proyectados x'_k, f siempre se escoge de modo que minimiza la ecuación 4-2 [21].

4.4. Marco experimental

4.4.1. Clasificación utilizando medidas direccionales

Para el caso de las medidas direccionales, los pesos de relevancia se ordenan de forma descendente y se hacen pruebas de clasificación primero con la características más relevantes, es decir, cuyo peso de relevancia es mayor dentro del conjunto de características (los 360 ángulos inicialmente). Luego se adiciona la característica con el segundo mayor peso y se clasifica de nuevo, y se continúa hasta obtener una estabilización del error de clasificación, que se usa como indicador de cuántas características relevantes son necesarias para clasificar correctamente las clases. Estas pruebas de clasificación se hacen para cada una de las ROIs segmentadas en el Capítulo 2 y los resultados se comparan con los obtenidos para ROIAB. Dado que se considera la información de cada ROI por separado, se utiliza la metodogía ILF, es decir, se consideran las 3 clases descritas en el capítulo 2.

4.4.2. Clasificación utilizando medidas estadísticas

Para el caso de las medidas estadísticas, el objetivo es verificar si los esquemas de filtrado considerados en el Capítulo 2 mejoran el desempeño de clasificación de las medidas consideradas en [48]. La diferencia en las representaciones tiene que ver con que ahora los datos se toman de una representación que tiene las mismas dimensiones de la imagen original, de modo que sobre esta se pueden aplicar las metodologías de identificación y localización.
Los esquemas de clasificación utilizados fueron los siguientes: primero, se utilizó un clasificador de $k-$ vecinos más cercanos; segundo, se utilizó un solo vecino, y se utilizó validación cruzada de 10 particiones, utilizando como porcentaje 70/30 para dividir las bases de datos en subconjuntos de entrenamiento/clasificación, es decir, en una prueba de clasificación se tiene un conjunto de 159 elementos con 7 características, entonces dicho conjunto se utiliza el 70 % para entrenar el clasificador, y el 30 % restante para clasificar. En el caso de las gráficas de error medio de clasificación, el error se grafica luego de estimar el error medio de clasificación que se obtiene como promedio tras 10 repeticiones en las que se hace clasificación.

4.4.3. Proyecciones utilizando escalamiento multidimensional

Se presentan gráficas con proyecciones hechas mediante escalamiento multidimensional con el propósito de ver cómo se afectan las muestras en las tres clases, tanto para ROIAB como para las ROIs segmentadas, una vez que se ha aplicado PCA. El propósito de estas pruebas es verificar algunos resultados relevantes, como por ejemplo si las características más relevantes en una ROI lo son en otra o no.

4.5. Resultados

4.5.1. Análisis de relevancia para las medidas direccionales

Utilizando los operadores de Prewitt y Sobel, se consideran las metodologías de preprocesamiento descritas en el capítulo 2. Para las representaciones obtenidas, se clasifica considerando inicialmente el total de las (360) direcciones de gradiente posibles. En este caso se utilizó ROIAB. Los resultados de la clasificación se muestran en la tabla **4-1**.

	Operador de gradiente	
Preproceso	kernel de Prewitt	kernel de Sobel
	0.22 ± 0.21	1,11 ± 0,35
Reconstrucción Biortogonal 3/5	2,89 ± 0,54	2,00 ± 0,49
LS Lazy wavelet Biortogonal 3/5	1,56 ± 0,70	2,89 ± 0,94

Tabla 4-1.: Error de clasificación para ROIAB utilizando como características todos los 360 ángulos de gradiente. Los resultados tienen la forma: $\mu_\epsilon \pm \sigma_\epsilon$.

En un segundo experimento se midieron los ángulos para cada una de las ROIs que fueron segmentadas utilizando transformada watershed (ver figuras 2.16(e) y 2.16(f)). El resto del procedimiento es igual al descrito en la etapa anterior. Además de dar indicios sobre la discriminancia de cada ROI por separado, este experimento se hizo para comparar la discriminancia de cada ROI respecto a ROIAB, y para establecer si el filtrado afecta la discriminancia de los ángulos de gradiente. Los resultados de este experimento se ven en la tabla **4-2**, la cual muestra los resultados de clasificación utilizando las 20 características más relevantes obtenidas del análisis de relevancia.

	Operador de Prewitt	
	Todas las características	20 características
ROI1	44,44 ± 1,37	22,44 ± 2,02
ROI2	46,00 ± 1,93	29,11 ± 1,42
ROI3	0,00 ± 1,34	3,11 ± 1,22
ROI4	14,44 ± 1,83	0,44 ± 0,82
ROI5	13,11 ± 1,88	5,77 ± 0,71
ROIAB	0,67 ± 0,32	5,78 ± 1,14

Tabla 4-2.: Error medio de clasificación (porcentaje) para 3 clases analizadas, antes y después de la selección de características. Los resultados tienen la forma: $\mu_\epsilon \pm \sigma_\epsilon$.

Gráficamente, la medición el error de clasificación siguiendo la metodología descrita en 4.4.1 se presenta en la figura **4-1**, en la que se clasificó con el conjunto de las 40 características más relevantes. Esta figura muestra que con las primeras 20 características se estabilizan las curvas de error de clasificación. Para algunas ROIs el requirimiento es mucho menor. Por ejemplo, para el caso de ROI4 (ver figura **2-12**) se requiren incluso menos de 10 características para discriminar correctamente las 3 condiciones de operación de la máquina.

4.5.2. Clasificación utilizando medidas estadísticas

En un primer experimento se compara el desempeño de clasificación que se obtiene con las 7 características, para la representación en píxeles y la basada en los coeficientes wavelet de aproximación. Los resultados se presentan en la tabla **4-3**, donde se muestra el error promedio de clasificación utilizando 3 cortes diferentes hechos para las imágenes: ROIM se refiere a un corte en el que se encuentra sólo el motor; ROIAB es el descrito en el marco experimental del Capítulo 2 y ALLROI contiene un corte en el que se muestra todo el banco de pruebas. Junto con los resultados de la clasificación, se presentan los pesos de relevancia. Esto permite hacer un par de conjeturas sobre la relevancia de las características, como por ejemplo que en todos los casos, el centroide de la curva del histograma presenta una mayor discrimancia que la media. Esto es consecuente con los resultados planteados en [9], pues en este caso se están considerando valores

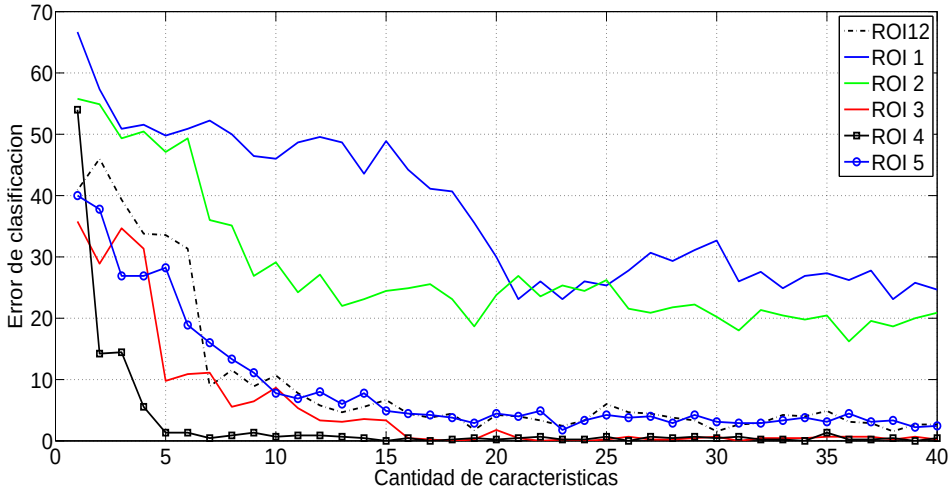

(a) Error de clasificación - Operador de Prewitt

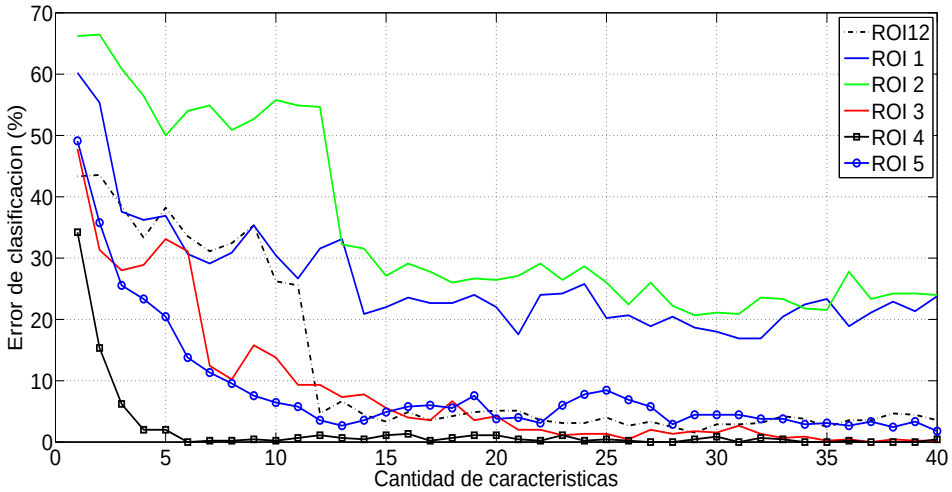

(b) Error de clasificación - Operador de Sobel

Figura 4-1.: Comparación – error de clasificación para las características en orden de relevancia descendente, para las 5 ROIs determinadas con la segmentación (ROI12 = ROIAB).

de temperatura, que se espera que ante cualquier fallo aumenten y que produzcan cambios en los histogramas. Aparte de esto, con las medidas de forma no es posible hacer ninguna conjetura, pues se desconocen las características de unimodalidad o multimodalidad de estos, luego medidas como la curtosis o la asimetría no tienen un significado claro.

Debe tenerse en cuenta que en los cortes hechos para ROIAB y ALLROI, por efecto de la gemotería de los rodamientos, necesariamente se incorpora una gran cantidad de fondo en las imágenes, a diferencia de ROIM en la que solo se conserva una pequeña parte del fondo que se encuentra en los bordes del motor. Para las dos primeras ROIs consideradas, puede verse sin necesidad de PCA que la entropía y MAD son las características que tienen una menor discriminancia. Hasta este punto,

		Característica						
Región de interés		Centroide	μ	σ	Asimetría	Curtosis	MAD	Entropía
ROIM	n.p.	0 ± 0	0 ± 0	0,67 ± 0,32	1,11 ± 0,35	4,22 ± 0,85	7,33 ± 0,89	9,55 ± 1,37
	Filtrado Biortogonal 3/5	0 ± 0	0,0 ± 0,0	0,88 ± 0,34	10,0 ± 1,05	0,0 ± 0,0	0,0 ± 0,0	2,44 ± 0,49
ROIAB	n.p.	0 ± 0	0,0 ± 0,0	0,88 ± 0,34	6,00 ± 0,77	3,55 ± 0,71	38,22 ± 1,85	11,33 ± 0,71
	nFiltrado Biortogonal 3/5	0 ± 0	13,33 ± 1,04	44,44 ± 1,44	0,0 ± 0,0	0,0 ± 0,0	0,67 ± 0,32	25,56 ± 1,14
ALLROI	n.p.	0 ± 0	0 ± 0	0,88 ± 0,34	3,77 ± 0,63	5,55 ± 0,47	41,56 ± 2,35	8,22 ± 0,95
	Filtrado Biortogonal 3/5	0,44 ± 0,42	0,0 ± 0,0	0,0 ± 0,0	0,0 ± 1,05	0,0 ± 0,0	0,0 ± 0,0	41,11 ± 2,09

Tabla 4-3.: Tasas de acierto de clasificación, considerando una sola característica a la vez.

queda claro que con la representación basada en píxeles, las medidas propuestas son suficientes para diagnosticar la condición de operación en la máquina, y que el análisis multiresolución podría tener efecto en la reducción del ruido presente en las imágenes. Dado que la etapa de localización utiliza una segmentación basada en transformada watershed, entonces cobra validez un análisis multiresolución para aumentar la relación señal a ruido en las imágenes y reduzca el efecto de máximos locales en la imagen, que puedan empeorar los resultados de la transformada.

	Preproceso	Índices - pesos de relevancia	Variación – PSNR
ROIM	No preproceso	1, 2, 4, 3, 6, 7, 5	
	Filtrado Biortogonal 3/5	2, 1, 4, 3, 6, 5, 7	15,55 ± 2,44
	LS Lazy wavelet Biortogonal 3/5	2, 1, 4, 3, 6, 5, 7	14,23 ± 2,22
ROIAB	No preproceso	3, 4, 7, 1, 2, 6, 5	
	Filtrado Biortogonal 3/5	3, 4, 6, 1, 2, 5, 7	17,25 ± 2,48
	LS Lazy wavelet Biortogonal 3/5	3, 4, 6, 1, 2, 5, 7	15,28 ± 2,57
ALLROI	No preproceso	3, 4, 1, 7, 2, 6, 5	
	Filtrado Biortogonal 3/5	3, 4, 6, 1, 2, 5, 7	15,65 ± 0,30
	LS Lazy wavelet Biortogonal 3/5	3, 4, 6, 1, 2, 5, 7	15,78 ± 0,63

Tabla 4-4.: Pesos de relevancia para las características estadísticas.

Los resultados de la tabla **4-4** muestran los pesos de relevancia que se obtienen para las medidas estadísticas en las tres ROIs del experimento anterior. Se indica el valor de la relación senãl a ruido pico (PSNR), pues independientemente de los cambios en la calidad de la representación respecto a las características consideradas, el hecho de filtrar la imagen tiene repercusiones en el PSNR que pueden influir en el desempeño de la segmentación con la transformada watershed. Se ha incluido intencionalmente como característica el valor del PSNR que se obtiene al comparar el error entre la imagen filtrada y la imagen original.

4.5.3. Análisis utilizando escalamiento multidimensional

Las figuras 4.2(a) y 4.2(b) muestran el resultado de utilizar MDS para ver como se agrupa el conjunto de las 159 muestras generadas a partir de ROIAB, cuando de utilizan las 360 características y las 20 filtradas, respectivamente.
Las figuras 4.3(a) y 4.3(b) muestran los resultados de hacer el mismo escalamiento multidimensional esta vez sobre ROI4 y ROI5, utilizando las 20 características más relevantes,

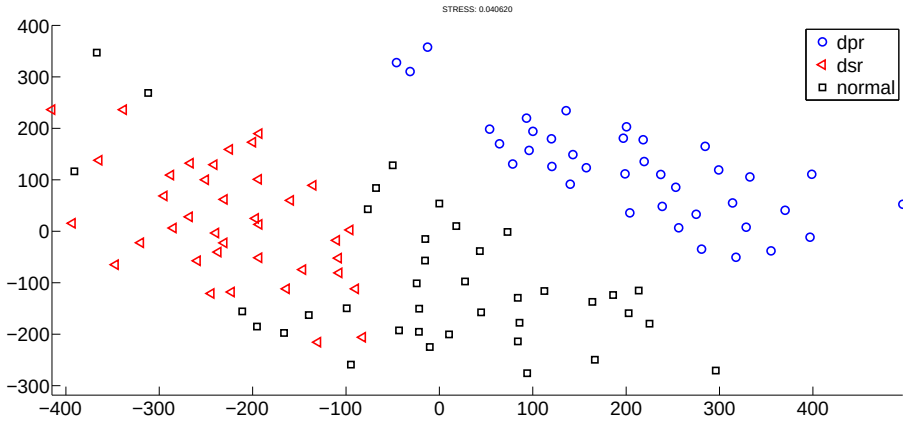

(a) 360 características

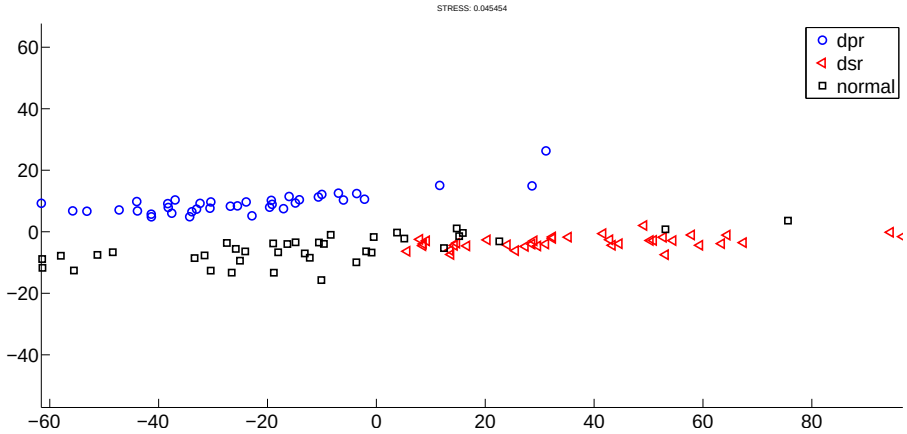

(b) 20 características, luego de PCA

Figura 4-2.: Proyección con MDS para ROIAB antes y después de la selección de características.

y utilizando el operador de Sobel, que fue para el que se obtuvieron los mejores resultados, según la figura 4.1(b). Los resultados demuestran que la utilización de las ROIs permite prescindir del procesamiento de regiones de las imágenes que como en el caso de ROI1 aporta poco a la clasificación.

4.6. Conclusiones

- El ordenamiento de los pesos es consecuente con el hecho de que las direcciones en las que se propaga el calor en las piezas inspeccionadas están limitadas por su geometría. En las imágenes, las piezas segmentadas ROIs están orientadas hacia estas direcciones, es decir, el eje y los rodamientos están dispuestos en las direcciones horizontal y vertical, y son hacia estas direcciones hacia las que se propaga el calor, además, las agrupaciones de las características relevantes de la Figura **3-3** sugieren que es posible seleccionar un número

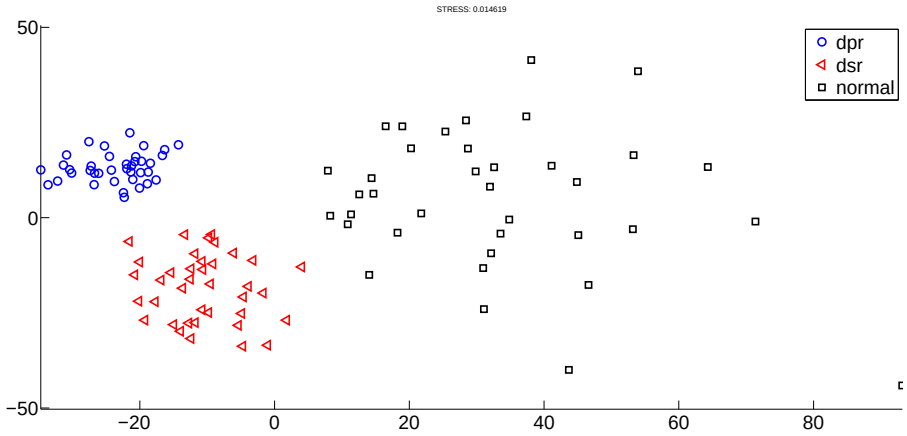

(a) 20 características, luego de PCA para ROI4.

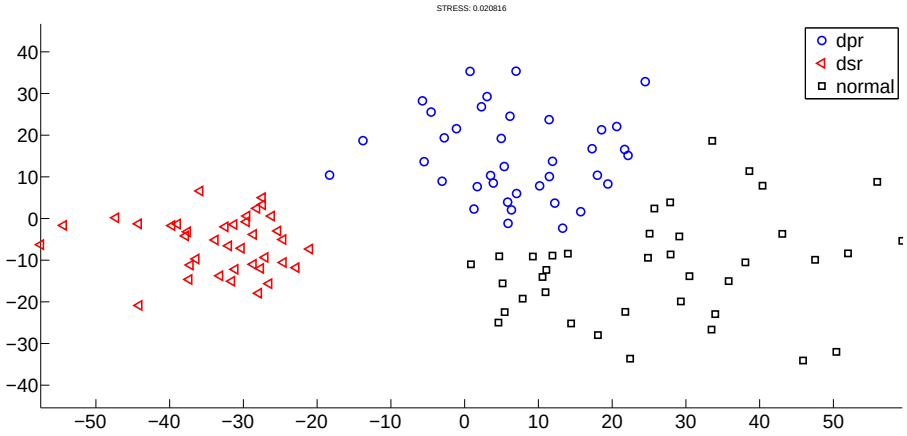

(b) 20 características, luego de PCA para ROI5.

Figura 4-3.: Proyección con MDS para 20 características, luego de PCA para ROI4 y ROI5. Resultados con operador de Prewitt

reducido de ángulos relevantes para caracterizar los fallos.

- El análisis de PCA permite descartar las características irrelevantes. Aquellas que resultan de la selección se agrupan alrededor de valores próximos a 90 grados y a sus múltiplos enteros. De la Figura **4-1** se puede establecer que en algunos casos, con menos de 10 características, se estabilizan las curvas de error de clasificación. Esto sugiere que analizando las ROIs extraídas de la transformada, se pueden discriminar perfectamente las condiciones de operación de la máquina, teniéndose en este caso una mayor interpretabilidad que al trabajar con la imagen completa.

- De la Figura **4-2** se puede detectar una de las dificultades de considerar el análisis global de varias ROIs simultáneamente en lugar de cada una de forma individual. Puede verse que al descartar características relevantes, la separabilidad de las clases disminuyó. Esto sugiere la

posibilidad de que las características relevantes para una ROI no lo sean para otra.

- Cualquier aseveración con respecto a cambios en la distribución de probabilidad de los píxeles en términos de variables como la curtosis o la asimetría está sujeta a que dicha distribución sea unimodal. Esto indica que un análisis basado en la distribución de probabilidad de los píxeles en una imagen, debe incluir estudios sobre las características de dicha distribución, como pruebas de bondad de ajuste.

- De acuerdo con los resultados de la tabla **4-4**, para efectos de clasificación no es necesario implementar una descomposición wavelet, pues las características utilizadas tienen igual desempeño en las representaciones de píxeles y de coeficientes wavalet de aproximación. Resulta notorio que prácticamente cualquier ROI de la imagen sea útil para clasificar las imágenes con las medidas consideradas. En la segunda columna de la tabla es posible ver que no todas las características tienen la misma relevancia, sin embargo hasta este punto no es posible hacer conclusiones respecto a la validez de las características pues fuera de los indicios sobre las imágenes que se obtuvieron en el capítulo anterior, no se conocen detalles de la distribución de probabilidad que tienen los píxeles en las ROIs sugeridas. Por esta razón es necesario analizar los resultados de pruebas de clasificación para cada ROI segmentada del fondo de las imágenes, pues éste puede llegar a ser una componente considerable de datos sin información de la imagen total, como en el caso de ROIAB.

5. Conclusiones generales

En este trabajo se ha presentado una nueva metodología de identificacíon y localización de fallas en máquinas rotativas utilizando imágenes termográficas. Para verificar el desempeño de esta metodología, se hicieron análisis para determinar el desempeño de las características que han sido propuestas en el estado el arte, y se introdujo una caracterización de los fallos basada en direcciones de gradiente, demostrando que la metodología permite aumentar la precisión en la identificación de los fallos, y que además permite establecer la ubicación espacial en las imágenes de los mismos.
El aumento en la precisión se obtuvo mediante una técnica modificada de umbralización mutinivel utilizada para binarizar las imágenes, la cual mejora el desempeño de la segmentación utilizando transformada watershed.
La localización de los fallos se hizo segmentando ROIs donde ocurren las mayores variaciones de temperatura en las imágenes. El análisis localizado de estas ROIs permite no solo disminuir el error en la clasificación de los fallos, si no también reducir el volumen de datos requerido.
Como conclusiones generales del trabajo, se obtuvieron los siguientes avances:

- Los resultados de las pruebas de clasificación muestran que el corte que contiene a ROIAB permite discriminar entre los fallos, y que en algunos casos no se requiere de ningún esquema de preprocesamiento. Sin embargo, la posibilidad de utilizar una región de interés en lugar de todo un corte de la imagen supone una gran ventaja en términos de tiempo de cómputo. Por otra parte, es notable que sea posible discriminar las condiciones de operación de la máquina, considerando una ROI que comparada con el conjunto total de la imagen es considerablemente pequeña, como es el caso de ROI1.

- Parte de la conveniencia de utilizar un flitrado wavelet, tiene que ver con que la etapa siguiente utiliza una transformada que es bastante sensible a los mínimos locales en la imagen.

- Los resultados de la binarización de las imágenes, muestran que la metodología tiene un desempeño bastante aceptable, al segmentar un contorno global de ROIAB muy similar al detectado por la transformada watershed.

- Los resultados del filtrado wavelet dependen de la aplicación. Por ejemplo, la representaciones que ofrece el filtrado wavelet conducen a resultados diferentes si por ejemplo se utilizan como etapas previas a la segmentación watershed.

- Pese a que en algunos casos se concluyó que daba lo mismo evaluar una característica en un corte de la imagen que en una ROI, ésta última opción tiene como ventaja indiscutible que require de mucha menos cantidad de datos que la primera. Esto se convierte en un factor crítico en el caso en que deban analizarse secuencias de imágenes. En este caso se compensa todo el pre y post proceso hecho a las imágenes para obtener una ROI, con la reducción en el tiempo de cómputo que ofrece este proceso, comparado con el de procesar el conjunto de la imagen.

- Fue evidente que los efectos de los desbalances analizados eran perceptibles en una gran parte de la maq́uina, lo que justifica la necesidad de implementar metodologías de identificación temprana de fallos.

5.1. Trabajos futuros

- Se recomienda implementar un enfoque basado en modelos que permita comparar los resultados de la dinámica de la máquina bajo prueba, con los resultados obtenidos con la metodología propuesta.

- Se debe verificar la dependencia estadística de las medidas para verificar si es lo mismo utilizar una o varias medidas para la identificación. Se podría verificar si aumenta la tasa de aciertos al utilizar combinaciones lineales de dos o más medidas.

- Considerar la posibilidad de utilizar los algoritmos sobre nuevas bases de datos que incluyan no solo otros fallos si no diferentes condiciones de operación como por ejemplo frenado o arranque de la máquina.

- Se recomienda realizar el filtrado de las imágenes con otro tipo de función wavelet, para minimizar la degradación de los bordes. Para ello, se recomiendan funciones direccionales como la contourlets.

A. Anexo: Intervalos de confianza y tolerancia

Los *intervalos de tolerancia*, de la forma $\mu \pm k\sigma$, con k constante positiva) [15] se utilizan para evaluar el desempeño de un clasificador, porque expresan la variabilidad de los elementos en una población. Por ejemplo, un intervalo de tolerancia del 95 % para una población indica que el 95 % de las observaciones caen en el intervalo. Los intervalos de tolerancia indican si dos categorías son separables o distinguibles. Por ejemplo, si los intervalos de confianza de dos categorías no se traslapan, se puede conluir que la presición de la asignación de las observaciones a sus respectivas clases es mayor que el nivel escogido para computar el intervalo. Por otra parte, el traslape de dos intervalos de tolerancia refleja directamente la proporción de observaciones mal clasificadas [2].

B. Anexo: Características estadísticas

Sea X una variable aleatoría de dimensión n, formada por el conjunto de elementos x_i cada uno de los cuales tiene un peso w_i, para la cual se definen los siguientes parámetros estadísticos:

B.1. Medidas de tendencia central

Definición B.1.1 *La media ponderada de los datos, o el centroide, definido como sigue:*

$$\mu_{w2} = \frac{\sum_{i=1}^{n} w_i x_i}{\sum_{i=1}^{n} w_i} \tag{B-1}$$

En algunos casos se prefiere sobre la media, ésta última puede asignar una mayor importancia a los valores extremos de la disctribución de probabilidad.

Definición B.1.2 *El valor medio de los datos, denotado usualmente como μ y definido por la ecuación B.1.2*

$$\mu = \frac{\sum_{i=1}^{N} x_i}{N} \tag{B-2}$$

y que representa un caso particular de la media ponderada, en la que se asigna el mismo peso (1) *para todos los valores. La valor medio da un indicador respecto a que valor se agrupan los datos en un conjunto de muestras [36].*

Definición B.1.3 *La entropía, definida como:*

$$Entropy = -\sum_{i} \sum_{j} c_{ij} \log 2c_{ij} \tag{B-3}$$

B.2. Medidas de dispersión

, que capturan la forma en que los datos están dispersos en términos absolutos o relativos, respecto a un valor de referencia que suele ser de tendencia central; con frecuencia éste valor es la media de los datos.

Definición B.2.1 *La desviación estándar, $\sigma_x = \sqrt{\sigma_x^2}$, en la que X es una variable aleatoria con función de probabilidad de masa $p(x)$ y valor esparado μ. El parámetro σ_x^2 es la varianza, y se define como sigue:*

$$\sigma^2 = \sum_D (x-\mu)^2 p(x) \tag{B-4}$$

Definición B.2.2 *La desviación media absoluta – (DMA), denotada por la expresión:*

$$\partial_{MAD} = \frac{1}{n}\sum_{i=1}^{n} |x_i - \bar{\mu}| \tag{B-5}$$

La DMA es la deviación promedio de todos los datos respecto a un valor de referencia, que usualmente es una medida de tendencia central. En el caso de la definición, tal medida es μ.

B.3. Medidas de forma

Definición B.3.1 *La asimetría, denotada por γ, y definida por la expresión:*

$$\gamma = \frac{E((x-E(X))^3)}{\sigma^{3/2}} \tag{B-6}$$

La asimetría mide el grado en el cual la función de densidad de probabilidad se “inclina” hacia un lado u otro del la curva que define su histograma.

Definición B.3.2 *La Curtosis, denotada por κ:*

$$\kappa = \frac{E((x-E(X))^4)}{\sigma^4} \tag{B-7}$$

Adicionalmente, en algunos de los experimentos de considera la relación señal a ruido pico, definida por la expresión, en la que ECM corresponde al error cuadrático medio.

$$PSNR = 10\log 10(\frac{MAX_I^2}{ECM}) \tag{B-8}$$

C. Patrones binarios direccionales

Un patrón binario direccional (PBD) define la textura en una vecindad de 3×3 píxeles en una imagen, como la distribución conjunta de probabilidad de los niveles de gris en los 9 píxeles $Z_c, Z_1, ..., Z_7$ siendo Z_c el pixel central en la vecindad, al rededor de los cual se encuentran $Z_0, ...Z_7$ [13]. La definción de PBD en una dirección está dada por la expresión:

$$\Delta I(Z_c)_\theta = I(Z_c) - I(Z_i), \left(i = 0, ..., 7; \theta = \frac{i\pi}{4}\right) \tag{C-1}$$

siendo θ la dirección en la cual se lleva a cabo la diferencia direccional, e i el pixel correspondiente. Para cada una de las posibles θ direcciones, la información sobre la diferencia direccional alrededor de Z_c se codifica en un PBD mediante la expresión:

$$PBD_\theta(Z_c) = \text{sign}(\Delta I(Z_0)_\theta), ..., \text{sign}(\Delta I(Z_7)_\theta) \tag{C-2}$$

donde

$$f(x) = \begin{cases} 1 & \text{si } \Delta I(Z_i)_\theta > 0, \\ 0 & \text{si } \Delta I(Z_i)_\theta \leq 0. \end{cases} \tag{C-3}$$

para $i = 0, ..., 7$.

C.1. Experimentos basados en PBD para las imágenes termográficas

Los PBD permiten identificar regiones de píxeles en la cuales se presentan gradientes de temperatura, y cuantificar dichos gradientes. En la figura **C-1** se muestra en resultado de superponer para cada pixel en la imagen, su correspondiente PBD a 45 grados.
En la figura **C-2** se ven algunos patrones obtenidos para ángulos relevantes al extraer PBD en las imágenes de la figura **C-1**.
Las principales limitaciones con los PBD son: primero, que debe determinarse el ángulo en el cual se enscuentran patrones relevantes, y segundo, que la selección de los elementos Z_i en la cuadrícula de 3 que forma el PBD es arbitraria, y no se debe determinar también si el orden asumido es el óptimo para hacer la representación.

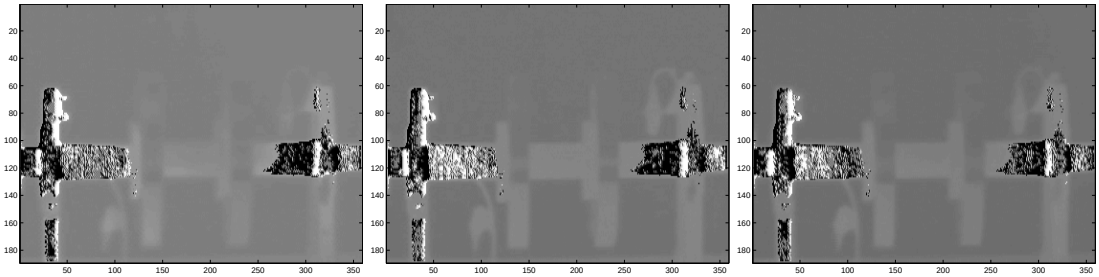

(a) PBD - imagen **normal** (b) PBD - imagen **dpr** (c) PBD - imagen **dsr**

Figura C-1.: Superposición de los PBD extraídos en imágenes en el mismo instante de tiempo, en las 3 condiciones consideradas.

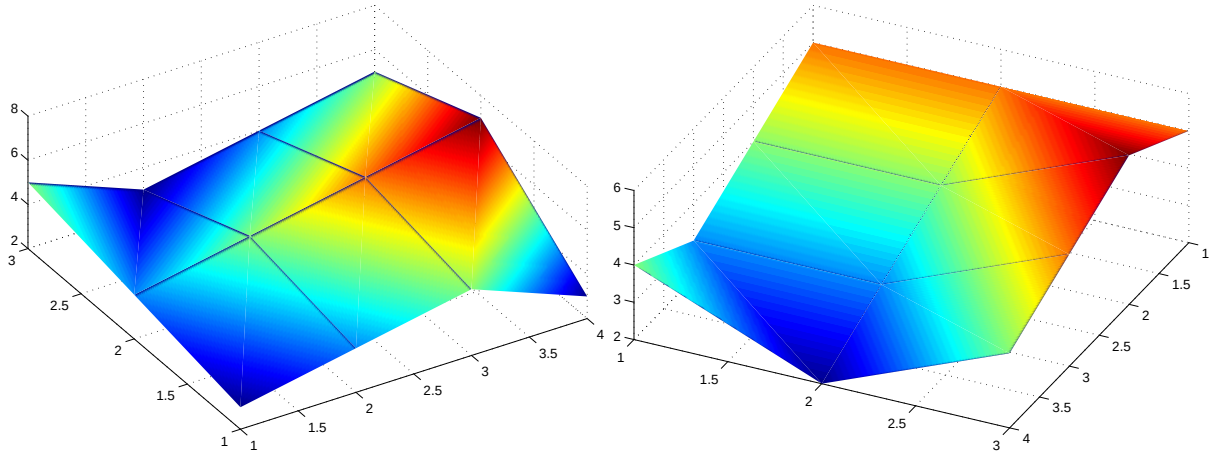

(a) DBP 34 (b) DBP 221

Figura C-2.: Detalle del conjunto de píxeles que generan a una ángulo de 45 grados, los patrones binarios direccionales 34 y 221.

D. Anexo: Discusión académica

- Gustavo Arango Argoty, Hermes Fandiño-Toro, Jorge Jaramillo-Garzón, Germán Castellanos-Domínguez. Predicción de funciones protéicas a partir de caracterización dinámica mediante representaciones tiempo-frecuencia, En: XV Simposio de tratamiento de señales, imágenes y visión artificial, Bogotá, 2010. Memorias del evento.

- Hermes Fandiño Toro, Julio César García Álvarez y Germán Castellanos. Metodología no invasiva de identificación de fallos asociados al desbalance del eje en motores, utilizando imágenes termográficas, En: XVI Simposio de tratamiento de seales, imágenes y visión artificial, Cali, 2011. Memorias del evento.

- Hermes Fandiño Toro, Julio César García Álvarez y Germán Castellanos. Performance evaluation of measures for the thermographic detection of motor faults by mass umbalance, En: The International Conference Surveillance 6, Compiègne, Francia 2011. Memorias del evento.

- Benhur Ortíz Jaramillo, Hermes Fandiño Toro, Hernán Benitez Restrepo, Sergio Orjuela Vargas, Germán Castellanos y W. Philips. Multi-resolution analysis for region of interest extraction in thermographic, nondestructive evaluation, En: Proceedings of SPIE (8295) 2012, p. 82951J.

Bibliografía

[1] Abbas, A.K. ; Heimann, K. ; Jergus, K. ; Orlikowsky, T. ; Leonhardt, S.: Neonatal non-contact respiratory monitoring based on real-time infrared thermography. En: *BioMedical Engineering OnLine* 10 (2011), Nr. 1, p. 93

[2] Abdi, H. ; Dunlop, J.P. ; Williams, L.J.: How to compute reliability estimates and display confidence and tolerance intervals for pattern classifiers using the Bootstrap and 3-way multidimensional scaling (DISTATIS). En: *NeuroImage* 45 (2009), Nr. 1, p. 89–95

[3] Arora, N. ; Martins, D. ; Ruggerio, D. ; Tousimis, E. ; Swistel, A.J. ; Osborne, M.P. ; Simmons, R.M.: Effectiveness of a noninvasive digital infrared thermal imaging system in the detection of breast cancer. En: *The American Journal of Surgery* 196 (2008), Nr. 4, p. 523–526

[4] Arora, S. ; Acharya, J. ; Verma, A. ; Panigrahi, P.K.: Multilevel thresholding for image segmentation through a fast statistical recursive algorithm. En: *Pattern Recognition Letters* 29 (2008), Nr. 2, p. 119–125

[5] Bellini, A. ; Filippetti, F. ; Tassoni, C. ; Capolino, G.A.: Advances in diagnostic techniques for induction machines. En: *Industrial Electronics, IEEE Transactions on* 55 (2008), Nr. 12, p. 4109–4126

[6] Beucher, S. ; Lantuéjoul, C.: Use of watersheds in contour detection. (1979)

[7] Bird, C.M. ; Beers, T.C.: Astronomical applications of distribution shape estimators. En: *The Astronomical Journal* 105 (1993), p. 1596–1606

[8] Corder, G.W. ; Foreman, D.I.: *Nonparametric statistics for non-statisticians: a step-by-step approach*. Wiley, 2011

[9] Fandiño-Toro, H.A. ; García-Álvarez, J.C. ; Castellanos-Domínguez, C.G.: Performance evaluation of measures for the thermographic detection of motor faults by mass unbalance. En: *Proceedings of the International Conference Surveillance 6*, 2011

[10] Fernández, S.F. ; Sánchez, J.M.C. ; Largo, A.C.: *Estadística descriptiva*. ESIC Editorial, 2002

[11] Figueiredo, M.A.T. ; Nowak, R.D.: An EM algorithm for wavelet-based image restoration. En: *Image Processing, IEEE Transactions on* 12 (2003), Nr. 8, p. 906–916

[12] Gao, X. ; Xiao, B. ; Tao, D. ; Li, X.: Image categorization: Graph edit distance+ edge direction histogram. En: *Pattern Recognition* 41 (2008), Nr. 10, p. 3179–3191

[13] Ge, H.: Gabor directional binary pattern: an image descriptor for gaze estimation. En: *EURASIP Journal on Advances in Signal Processing* 2010 (2010), p. 57

[14] Gonzalez, R.C. ; Richard, E. *Woods, digital image processing*. 2002

[15] Hahn, G.J. ; Meeker, W.Q.: *Statistical intervals: a guide for practitioners*. Vol. 328. Wiley-Interscience, 2011

[16] Hashemian, HM: Wireless sensors for predictive maintenance of rotating equipment in research reactors. En: *Annals of Nuclear Energy* 38 (2011), Nr. 2, p. 665–680

[17] Heng, A. ; Zhang, S. ; Tan, A.C.C. ; Mathew, J.: Rotating machinery prognostics: State of the art, challenges and opportunities. En: *Mechanical Systems and Signal Processing* 23 (2009), Nr. 3, p. 724–739

[18] Herry, C.L. ; Frize, M.: Quantitative assessment of pain-related thermal dysfunction through clinical digital infrared thermal imaging. En: *BioMedical Engineering OnLine* 3 (2004), Nr. 1, p. 19

[19] Hoppler, R. ; Errath, RA: Motor bearings, not must a piece of metal. En: *Cement Industry Technical Conference Record, 2007. IEEE* IEEE, 2007, p. 214–233

[20] Jakubowska, T. ; Wiecek, B. ; Wysocki, M. ; Drews-Peszynski, C.: Thermal signatures for breast cancer screening comparative study. En: *Engineering in Medicine and Biology Society, 2003. Proceedings of the 25th Annual International Conference of the IEEE* Vol. 2 IEEE, 2003, p. 1117–1120

[21] Kruskal, JB ; Wish, M.: Multidimensional Scaling. 1978. En: *Beverly Hills, CA*

[22] Lee, H. ; Park, R.H.: Comments on “An optimal multiple threshold scheme for image segmentation”. En: *Systems, Man and Cybernetics, IEEE Transactions on* 20 (1990), Nr. 3, p. 741–742

[23] Li, C.J. ; Lee, H.: Gear fatigue crack prognosis using embedded model, gear dynamic model and fracture mechanics. En: *Mechanical systems and signal processing* 19 (2005), Nr. 4, p. 836–846

[24] Li, Y. ; Billington, S. ; Zhang, C. ; Kurfess, T. ; Danyluk, S. ; Liang, S.: Adaptive prognostics for rolling element bearing condition. En: *Mechanical systems and signal processing* 13 (1999), Nr. 1, p. 103–113

[25] Maldague, X.: Applications of infrared thermography in nondestructive evaluation. En: *Trends in optical nondestructive testing* (2000), p. 591–609

[26] Maurer Jr, C.R. ; Qi, R. ; Raghavan, V.: A linear time algorithm for computing exact euclidean distance transforms of binary images in arbitrary dimensions. En: *Pattern Analysis and Machine Intelligence, IEEE Transactions on* 25 (2003), Nr. 2, p. 265–270

[27] Meola, C. ; Giorleo, G. ; Nele, L. ; Squillace, A. ; Carlomagno, GM: Infrared thermography in the quality assurance of manufacturing systems. En: *Nondestructive Testing and Evaluation* 18 (2002), Nr. 2, p. 83–90

[28] Meyer, F. ; Beucher, S.: Morphological segmentation. En: *Journal of visual communication and image representation* 1 (1990), Nr. 1, p. 21–46

[29] Morse, B.S.: Lecture 4: Thresholding. En: *Brigham Young University, Utah* (2000)

[30] Niola, V. ; Quaremba, G. ; Amoresano, A.: A study on infrared thermography processed trough the wavelet transform. En: *Proceedings of the 8th WSEAS international conference on System science and simulation in engineering* World Scientific and Engineering Academy and Society (WSEAS), 2009, p. 57–62

[31] Oliver, A. ; Freixenet, J. ; Martí, J. ; Pérez, E. ; Pont, J. ; Denton, E.R.E. ; Zwiggelaar, R.: A review of automatic mass detection and segmentation in mammographic images. En: *Medical Image Analysis* 14 (2010), Nr. 2, p. 87–110

[32] Ortiz-Jaramillo, B. ; Fandiño-Toro, H.A. ; Benitez-Restrepo, H.D. ; Orjuela-Vargas, S.A. ; Castellanos-Domínguez, G. ; Philips, W.: Multi-resolution analysis for region of interest extraction in thermographic, nondestructive evaluation. En: *Proceedings of SPIE* Vol. 8295, 2012, p. 82951J

[33] Otsu, N.: A threshold selection method from gray-level histograms. En: *Automatica* 11 (1975), p. 285–296

[34] Papamarkos, N. ; Gatos, B.: A new approach for multilevel threshold selection. En: *CVGIP: Graphical Model and Image Processing* 56 (1994), Nr. 5, p. 357–370

[35] Qiu, J. ; Seth, B.B. ; Liang, S.Y. ; Zhang, C.: Damage mechanics approach for bearing lifetime prognostics. En: *Mechanical systems and signal processing* 16 (2002), Nr. 5, p. 817–829

[36] Rachev, S.T. ; Hoechstoetter, M. ; Fabozzi, F.J. ; Focardi, S.M. [u. a.]: *Probability and Statistics for Finance*. Vol. 176. Wiley, 2010

[37] Roerdink, J.B.T.M. ; Meijster, A.: The watershed transform: Definitions, algorithms and parallelization strategies. En: *Fundamenta Informaticae* 41 (2000), Nr. 1-2, p. 187–228

[38] Shimazaki, H. ; Shinomoto, S.: A method for selecting the bin size of a time histogram. En: *Neural Computation* 19 (2007), Nr. 6, p. 1503–1527

[39] Sobel, I.: Neighborhood coding of binary images for fast contour following and general binary array processing. En: *Computer Graphics and Image Processing* 8 (1978), Nr. 1, p. 127–135

[40] Sturges, H.A.: The choice of a class interval. En: *Journal of the American Statistical Association* 21 (1926), Nr. 153, p. 65–66

[41] Tandon, N. ; Parey, A.: *Condition Monitoring of Rotary Machines*. Springer London, 2006 (Springer Series in Advanced Manufacturing). – 109–136 p.. – ISBN 978–1–84628–269–0

[42] Venna, J. ; Kaski, S.: Local multidimensional scaling. En: *Neural Networks* 19 (2006), Nr. 6-7, p. 889–899

[43] Wang, S. ; Chung, F. ; Xiong, F.: A novel image thresholding method based on Parzen window estimate. En: *Pattern Recognition* 41 (2008), Nr. 1, p. 117–129

[44] Wang, Z. ; Bovik, A.C. ; Sheikh, H.R. ; Simoncelli, E.P.: Image quality assessment: From error visibility to structural similarity. En: *Image Processing, IEEE Transactions on* 13 (2004), Nr. 4, p. 600–612

[45] Widodo, A. ; Satrijo, D. ; Huda, M. ; Lim, G.M. ; Yang, B.S.: Application of Self Organizing Map for Intelligent Machine Fault Diagnostics Based on Infrared Thermography Images. En: *Bio-Inspired Computing: Theories and Applications (BIC-TA), 2011 Sixth International Conference on* IEEE, 2011, p. 123–128

[46] Worden, K. ; Staszewski, W.J. ; Hensman, J.J.: Natural computing for mechanical systems research: A tutorial overview. En: *Mechanical Systems and Signal Processing* 25 (2011), Nr. 1, p. 4–111

[47] Younus, A. ; Yang, B.S.: Intelligent fault diagnosis of rotating machinery using infrared thermal image. En: *Expert Systems With Applications* (2011)

[48] Younus, A.M. ; Yang, B.S.: Wavelet co-efficient of thermal image analysis for machine fault diagnosis. En: *Proceedings of the International Conference on Mechanical Engineering, ICME09.*, 2009, p. 1–6