

**MONITOREO DE REGÍMENES DE DESGASTE POR MEDIO DE TÉCNICAS DE
ANÁLISIS DE IMAGEN Y APRENDIZAJE DE MÁQUINA**

Autor:

CAMILO ERNESTO GONZÁLEZ ARIAS

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICOQUÍMICAS
ESCUELA DE INGENIERÍA METALÚRGICA Y CIENCIA DE MATERIALES
BUCARAMANGA, SANTANDER
AÑO 2019

**MONITOREO DE REGÍMENES DE DESGASTE POR MEDIO DE TÉCNICAS DE
ANÁLISIS DE IMAGEN Y APRENDIZAJE DE MÁQUINA**

Autor:

CAMILO ERNESTO GONZÁLEZ ARIAS

TRABAJO DE GRADO (Modalidad, proyecto de investigación)
PARA OPTAR POR EL TÍTULO DE INGENIERO METALÚRGICO

Director:

Dr. CRISTIAN CAMILO VIÁFARA ARANGO
ESCUELA INGENIERÍA METALÚRGICA Y CIENCIAS DE MATERIALES

Codirector:

FABIO MARTINEZ CARRILLO
ESCUELA INGENIERÍA DE SISTEMAS E INFORMÁTICA

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICOQUÍMICAS
ESCUELA DE INGENIERÍA METALÚRGICA Y CIENCIA DE MATERIALES
BUCARAMANGA, SANTANDER
AÑO 2019

DEDICATORIA

A Dios por cumplir su propósito en mi día tras día.

A mi padre que ha sido mi motivación, el motor de mi vida y me ha brindado su apoyo incondicional para seguir siempre hacia adelante.

A mi madre por apoyarme, amarme, confiar siempre en mi y enseñarme que todo es posible.

A mi novia, compañera y mejor amiga, por su constante apoyo y motivación.

A mi familia por estar a mi lado durante toda esta etapa y creer en mi.

A la familia Ayala Vilorio por su cariño, apoyo y por hacerme sentir como uno más de ellos.

AGRADECIMIENTOS

Al Ingeniero y profesor Cristian Camilo Viáfara Arango, por su apoyo, orientación, paciencia y por estar siempre atento y dispuesto para resolver cualquier duda e inconveniente.

Al profesor Fabio Martínez Carrillo y a su grupo de Investigaciones en Ingeniería Biomédica de la Escuela de Ingeniería de Sistemas e Informática por su orientación y disposición.

A todos los profesores de la Escuela de Ingeniería Metalúrgica por su cordialidad y disposición constante para escuchar, orientar, ayudar y sobre todo formar al estudiante.

A todos los técnicos de la escuela de Ingeniería Metalúrgica: Sergio, Domingo, Ambrosio, Javier, Mario y Oscar por su orientación, disposición y ayuda.

A la Universidad Industrial de Santander (UIS) por permitirme hacer parte de esta honorable comunidad universitaria y ser el lugar donde pude hacer realidad uno de mis principales sueños.

TABLA DE CONTENIDO

INTRODUCCIÓN	12
1. ANTECEDENTES	14
1.1. INTRODUCCIÓN AL DESGASTE	14
1.1.1. Desgaste abrasivo.....	15
1.2. MONITOREO Y DETECCIÓN DE DESGASTE.....	16
1.2.1. Métodos directos	16
1.2.2. Métodos indirectos	18
2. OBJETIVOS	21
2.1. OBJETIVO GENERAL.....	21
2.2. OBJETIVOS ESPECÍFICOS.....	21
3. METODOLOGÍA	22
3.1. REVISIÓN BIBLIOGRÁFICA	22
3.2. SELECCIÓN Y CLASIFICACIÓN DE IMÁGENES	22
3.3. APLICACIÓN DEL HISTOGRAMA DE GRADIENTE ORIENTADO (HOG)	25
3.4. IMPLEMENTACIÓN DE LOS CLASIFICADORES	26
3.4.1. Gaussian Naive Bayes (Gauss)	27
3.4.2. Decision Tree (DT)	28
3.4.3. Random Decision Forest (RaF).....	28
3.5. VALIDACIÓN ESTADÍSTICA.....	29
4. RESULTADOS Y DISCUSIÓN	30
4.1. DESCRIPTOR HOG.....	30
4.2. ANÁLISIS DE LA VALIDACIÓN CRUZADA DE LOS CLASIFICADORES	32
5. CONCLUSIONES	36
6. RECOMENDACIONES	37
REFERENCIAS BIBLIOGRÁFICAS	38
BIBLIOGRAFÍA	41

LISTA DE TABLAS

1.	Tabla 1. Descripción y dureza de los materiales de prueba [1].	22
2.	Tabla 2. Descripción y dureza de las partículas abrasivas [1].	23
3.	Tabla 3. Resultados de precisión (%) para los clasificadores con diferentes orientaciones HOG.	33
4.	Tabla 4. Resultados de precisión (%) para los clasificadores con diferentes tamaños de celda HOG.	34

LISTA DE FIGURAS

1.	Figura 1. Curvas de fricción (a) y desgaste (b) en función del tiempo que muestran los niveles críticos para una aplicación determinada (adaptada de [2]).....	14
2.	Figura 2. Esquema de un sistema tribológico (adaptada de [3]).	15
3.	Figura 3. Tasa de desgaste de los materiales de muestra en función de la relación de dureza (H_A/H) [1].....	23
4.	Figura 4. Imágenes SEM de las superficies desgastadas para las condiciones F14-Vidrio (a), Fa-Vidrio (b), F24-Granate (c), M-SiC (d), M-Granate © y Fm-Granate(f).....	24
5.	Figura 5. Ejemplo ilustrativo del cálculo del descriptor HOG sobre una imagen SEM.....	26
6.	Figura 6. Resultados HOG para las imágenes de superficies desgastadas en el régimen de desgaste moderado y severo con diferentes configuraciones.....	31
7.	Figura 7. Resultados de los valores de precisión media de los clasificadores para diferentes configuraciones de parámetros HOG	32
8.	Figura 8. Resultados de los valores de precisión máxima de los clasificadores para diferentes configuraciones de parámetros HOG.	33
9.	Figura 9. Resultados de precisión en términos del número de k – fold para las configuraciones 16-c64-b42 (a) y 16-c16-b42 (b).....	35

RESUMEN

TITULO: MONITOREO DE REGÍMENES DE DESGASTE POR MEDIO DE TÉCNICAS DE ANÁLISIS DE IMAGEN Y APRENDIZAJE DE MÁQUINA

AUTOR: CAMILO ERNESTO GONZÁLEZ ARIAS

PALABRAS CLAVE: MONITOREO DEL DESGASTE, TÉCNICAS DE PROCESAMIENTO DE IMÁGENES, DESCRIPTOR HOG, REGIMENES DEL DESGASTE ABRASIVO, DESGASTE MODERADO, DESGASTE SEVERO.

El objetivo principal de este trabajo fue desarrollar una nueva estrategia computacional capaz de predecir la operación del régimen de desgaste en superficies desgastadas. Para desarrollar la investigación se tomaron imágenes de las superficies desgastadas de especímenes de fundiciones de hierro sometidas a ensayos de desgaste por abrasión. Estas imágenes se clasificaron en dos grupos, identificados con las etiquetas severo y moderado, de acuerdo con los resultados de la tasa de desgaste encontrados durante las pruebas de desgaste. Las características de la superficie de las imágenes desgastadas se codificaron con un descriptor de histograma denso de gradiente orientado (HOG) y, luego, se implementaron diferentes modelos de clasificadores para obtener un modelo de aprendizaje de la severidad del desgaste. Los modelos de clasificadores utilizados fueron Gaussian Naive Bayes, Decision Tree y Random Forest. Dichos modelos abarcan la familia de clasificadores usados para obtener desde implementaciones rápidas hasta implementaciones robustas. Se realizó una evaluación de la capacidad de los clasificadores para identificar las imágenes correspondientes a los regímenes de desgaste severo y moderado siguiendo una estrategia de validación cruzada de k-fold. La caracterización cualitativa de las imágenes de superficies desgastadas a través del cálculo de HOG y la aplicación de modelos de clasificadores permiten predecir asertivamente si operaron regímenes de desgaste abrasivo moderado o severo en las superficies analizadas. La metodología propuesta alcanza más del 80 % de precisión en casi todas las configuraciones del HOG y los diferentes clasificadores aquí evaluados.

Trabajo de grado (modalidad, proyecto de investigación)
Escuela de Ingeniería Metalúrgica y Ciencia de Materiales
Director: Dr. Cristian Camilo Viáfara Arango, Ingeniero Mecánico.

ABSTRACT

TITLE: MONITORING OF WEAR REGIMES THROUGH IMAGE ANALYSIS TECHNIQUES AND LEARNING MACHINE

AUTHOR: CAMILO ERNESTO GONZÁLEZ ARIAS

KEYWORDS: WEAR MONITORING, IMAGE PROCESSING TECHNIQUES, HOG DESCRIPTOR, ABRASIVE WEAR REGIME, MILD WEAR, SEVERE WEAR.

The main objective of this work was to develop a novel computational strategy that is able to predict wear regime operation in worn surfaces. The image data were taken from worn surfaces images of cast iron specimens were under to abrasion wear tests. These images were classified into two groups, identified with the severe and mild labels, according to the wear rate results found during the wear tests. The surface features of worn surfaces images were coded as a dense Histogram of Oriented Gradient (HOG) descriptor and thus classifiers models were here in implemented to obtain a learning model of wear severity. Gaussian Naive Bayes, Decision Tree and Random Forest were the classifier models used, which span the family of classifiers from fast to robust implementations. An evaluation of the classifier capacity to identify those images corresponding to the severe and mild wear regimes was made by following a k-fold cross validation strategy. The qualitative characterization of worn surfaces images through the HOG computation and the application of classifier models allow predicting well whether a mild or a severe abrasive wear regime operated. The proposed methodology achieves more than 80 % of accuracy in almost all HOG configurations and for the different classifiers here in evaluated.

Trabajo de grado (modalidad, proyecto de investigación)
Escuela de Ingeniería Metalúrgica y Ciencia de Materiales
Director: Dr. Cristian Camilo Viáfara Arango, Ingeniero Mecánico.

INTRODUCCIÓN

El desgaste se puede definir como el daño que se produce en la superficie de dos materiales sólidos por la interacción y el movimiento entre ellos. Este fenómeno juega un papel muy importante en la determinación de la vida útil de los componentes de máquinas [4]. Este es un proceso dinámico y complejo puesto que depende diversos aspectos como la rugosidad de las superficies en contacto, las propiedades mecánicas de los materiales, la geometría y dinámica de los cuerpos, las condiciones de operación, entre otros factores. Este proceso involucra pérdidas de masa, energía y tiempo, lo cual se traduce en grandes inversiones económicas en actividades de mantenimiento, reparación e incluso cambio de equipos [5].

El desgaste ha sido ampliamente estudiado, pero debido a la complejidad de este fenómeno usualmente las mediciones de desgaste se realizan cuando el proceso ya ha finalizado. Es decir, para realizar un mantenimiento, reparación o un análisis de la evolución de un proceso de desgaste que se está efectuando en un elemento de una máquina es necesario detener el equipo y desmontar el componente a inspeccionar. Estas paradas generan una disminución en los tiempos de producción, lo cual se traduce en grandes pérdidas económicas para la industria [5].

Actualmente los métodos más usados para medir la evolución del desgaste se pueden dividir en dos tipos, medición directa y medición indirecta. Entre los métodos de medición directa los más representativos son los que miden la diferencia de masa, el volumen de desgaste y la diferencia topográfica. De los métodos de medición indirecta se puede decir que aún no están completamente desarrollados, pues muchos son objeto de estudio actualmente. Algunos de estos métodos consisten en el monitoreo de la evolución de los procesos de desgaste por análisis de imágenes de superficies desgastadas [6, 7], por el análisis de partículas de desgaste presentes en el aceite de lubricación [8, 9] o por el análisis de vibraciones [10, 9].

Tanto los métodos de medición directa como los de medición indirecta presentan fallas a la hora de realizar el monitoreo de la evolución de un proceso de desgaste. Por ejemplo, la medición de la diferencia de masa a pesar de que es un método rápido y económico requiere detener el proceso de desgaste y además no es efectiva para situaciones donde la pérdida de masa es muy baja. Sumado a lo anterior, la pérdida de masa no da información de la evolución del desgaste en la superficie y no tiene en cuenta la transferencia de material entre las superficies en contacto [4]. Por otro lado, los métodos de medición indirecta como el análisis de partículas presentes en el aceite de lubricación son opciones para monitorear un proceso de desgaste sin tener que interrumpir dicho

proceso, pero presentan dificultades a la hora de ser implementados en la industria. Por ejemplo, la principal limitación en la implementación del análisis de partículas presentes en el aceite de lubricación es que solo se puede realizar en máquinas lubricadas con aceite u otro fluido similar y además los equipos usados para analizar dichas partículas son costosos [8].

Otros métodos para la detección y el monitoreo del desgaste han sido propuestos y estudiados, como es el caso del monitoreo de la condición de desgaste a través del procesamiento de imágenes. Estas técnicas han sido ampliamente investigadas teniendo en cuenta sus muchas ventajas y se han aplicado a diferentes tipos de análisis, como la detección de desgaste de herramientas de corte [11, 12] y el análisis de partículas de desgaste [13, 14]. La principal ventaja del monitoreo de desgaste por procesamiento de imágenes es que este sistema está basado en la visión por computadora, por ende, puede ser automatizado fácilmente, permitiendo así obtener mediciones en línea, precisas, confiables y sin contacto entre el instrumento de medición y los elementos sometidos a desgaste. Con lo anterior se puede lograr una inspección continua, económica y rápida de las superficies desgastadas [4, 15].

Una prometedora aplicación para el método descrito anteriormente es la detección y monitoreo de los regímenes presentes en un proceso de desgaste, los cuales están asociados directamente a los mecanismos de desgaste (como se explicará más adelante). Los mecanismos y regímenes de desgaste mencionados dependen directamente del sistema tribológico, el cual está basado en todas las variables y componentes que afectan el fenómeno del desgaste [3].

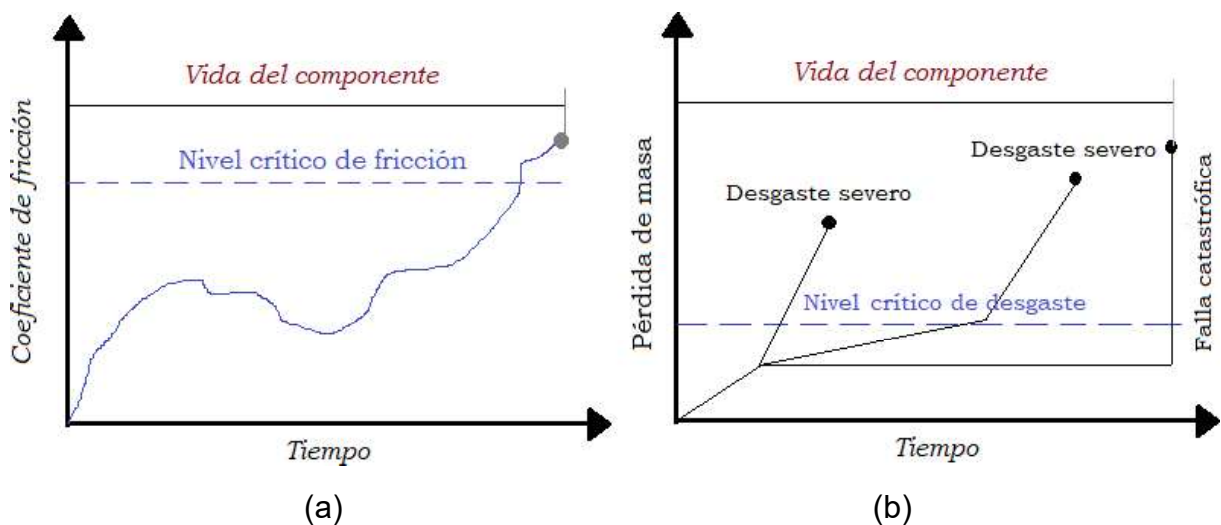
La problemática descrita sugiere que es propicio desarrollar un sistema que permita monitorear los regímenes de desgaste y detectar una transición entre ellos usando el procesamiento de imágenes y el aprendizaje de máquina. Este sistema debe permitir examinar un proceso de desgaste sin tener que detenerlo, aumentando así la confiabilidad de las inspecciones realizadas y supliendo las falencias de los actuales métodos de monitoreo.

1. ANTECEDENTES

1.1. INTRODUCCIÓN AL DESGASTE


El desgaste es un fenómeno que ha acompañado al hombre desde el principio de los tiempos, que es complejo y difícil de predecir. En la Figura 1 se presentan unas curvas en el tiempo que representan los niveles críticos de fricción y desgaste que pueden llevar a incumplir los requisitos exigidos por una aplicación determinada. Este fenómeno se presenta de diferentes modos. El patrón de daño de las superficies depende de las condiciones en que ocurre el proceso de desgaste, en este orden de ideas el desgaste puede ser por deslizamiento, abrasión, erosión o rodadura. Los diferentes fenómenos por los cuales se remueve material son a lo que se denomina mecanismos de desgaste [3]. Cuando uno de estos mecanismos actúa de forma predominante se establece un régimen de desgaste asociado. El régimen de desgaste hace referencia a un periodo de tiempo en donde la tasa de desgaste o tasa de pérdida de material permanece constante [3].

Figura 1. Curvas de fricción (a) y desgaste (b) en función del tiempo que muestran los niveles críticos para una aplicación determinada (adaptada de [2]).



La operación de los regímenes de desgaste mencionados anteriormente depende directamente del sistema tribológico. Por lo general un tribosistema (Figura 2) está conformado por cuatro elementos: El cuerpo sólido, el contracuerpo, el elemento interfacial y el ambiente o la atmósfera en la que se lleva a cabo el proceso [3]. Se ha reportado que pequeñas variaciones en el tribosistema podrían ocasionar una transición entre los regímenes [16].

Figura 2. Esquema de un sistema tribológico (adaptada de [3]).



1.1.1. Desgaste abrasivo. El desgaste abrasivo es un fenómeno que se presenta en la mayoría de los procesos productivos. Las superficies de los materiales sufren los efectos de partículas abrasivas provenientes de los procesos productivos o externas, las cuales provocan pérdidas masa o deformación plástica en dichas superficies [17]. El desgaste abrasivo tiene la peculiaridad de estar fuertemente influenciado por las características de las partículas abrasivas, como la dureza, el tamaño y la morfología [1]. Investigaciones muestran que, para tamaños de grano abrasivo por debajo del tamaño de partícula crítica, la tasa de desgaste aumenta con el tamaño de abrasivo, y por encima de este tamaño de partícula la tasa de desgaste aumenta mucho más lentamente [18, 19].

Existen dos mecanismos predominantes en el desgaste abrasivo, el mecanismo de microcorte y el de deformación plástica (macrodeformación). Como se mencionó anteriormente cada mecanismo que actúa de forma predominante produce un régimen de desgaste asociado. En el caso del mecanismo de microcorte actúa un régimen de desgaste severo y en el mecanismo de macrodeformación actúa un régimen de desgaste moderado[1].

Un factor importante en este tipo de desgaste es la dureza de la partícula abrasiva, pues dicho parámetro puede generar una transición entre los regímenes. Es decir, si la dureza de las partículas abrasivas es superior a la del material y si se sobrepasa el límite de rotura del mismo, entra en acción el mecanismo de microcorte (generando partículas de desgaste) [1]. Por otro lado, si la dureza de la partícula es baja y las tensiones de contacto son inferiores al límite de rotura, entra en acción del mecanismo de macrodeformación, produciendo el rayado o raspado de las superficies en dirección arbitraria, pero no se generan partículas de desgaste (baja tasa de desgaste) [1].

Como se puede apreciar, tanto en el desgaste abrasivo como en el desgaste por deslizamiento es muy importante mantener controladas las transiciones entre regímenes.

Es bien sabido que se debe impedir la operación del régimen severo, pues este régimen tiene una tasa de desgaste alta, lo cual aumenta el deterioro y por ende el riesgo de falla de los elementos sometidos a desgaste.

Con el fin de aumentar la durabilidad y la confiabilidad de los elementos sometidos a desgaste, se han implementado algunos métodos de monitoreo y detección de desgaste, los cuales se explicarán brevemente a continuación.

1.2 MONITOREO Y DETECCIÓN DE DESGASTE

Se han desarrollado diferentes métodos para realizar mediciones de desgaste. Dichos métodos se pueden clasificar en dos tipos, medición directa y medición indirecta.

1.2.1 Métodos directos. En esta sección se describirán algunos métodos de medición directa. Los métodos que se detallarán a continuación serán: diferencia de masa, medición lineal del desgaste, área de desgaste, volumen de desgaste y diferencia topográfica.

- ✓ Diferencia de masa. Esta es una de las formas más rápidas, económicas y prácticas para medir la cantidad de desgaste. Este método consiste básicamente en tomar una muestra y pesarla, someterla a una condición de desgaste y pesar la muestra después de que el proceso haya finalizado, lo que permite cuantificar la tasa de desgaste. La cantidad de desgaste se puede describir por la pérdida de masa absoluta (en gramos), la tasa de pérdida de masa por unidad de tiempo (gramos por día) [4, 17]. Este método de medición tiene ciertas dificultades o desventajas a pesar de ser uno de los más usados. La primera es que este tipo de medición es adecuada para muchas pruebas de laboratorio, así como en aplicaciones reales, pero sólo si el componente desgastado es desmontable. Otra desventaja es que para procesos de desgaste donde la pérdida de masa es insignificante en relación a la masa total del componente, no es posible realizar la medición y como ya se mencionó anteriormente, la pérdida de masa no da información de la evolución del desgaste en la superficie y no tiene en cuenta la transferencia de material entre las superficies en contacto [4].
- ✓ Volumen de desgaste. En casi todos los procesos de desgaste suele haber pérdida o deformación plástica del material, es por eso que la medición de volumen de desgaste es uno de los métodos más utilizados para la cuantificación del desgaste

en un elemento [4]. La medición del volumen de desgaste requiere conocer el volumen inicial y final (volumen después de ser sometido a desgaste) del elemento a analizar, simplemente se hace una comparación entre estos volúmenes y se asocia a la cantidad de desgaste que sufrió el elemento.

A pesar de que este método es económico y muy usado, tiene algunas dificultades, por ejemplo, que las mediciones de los volúmenes suelen requerir mucho tiempo y esfuerzo (puesto que muchas veces los elementos que se requieren medir tienen formas irregulares y además estas mediciones de los volúmenes deben ser muy precisas) [17]. Una falencia que tiene este método es que no ofrece información sobre la evolución o distribución del desgaste en el elemento analizado.

- ✓ Diferencia topográfica. En los métodos presentados anteriormente la medición del desgaste se había analizado solo a escala macroscópica, pero este tipo de medición (diferencia topográfica) se enfoca en la información local que se podría decir es más útil y valiosa, ya que el desgaste se da también a escala microscópica entre las asperezas presentes en las superficies en contacto [4]. El desgaste modifica la morfología de la superficie lo cual permite monitorear la distribución y evolución del mismo por medio de la determinación de la elevación de los puntos de la superficie, es decir hay un cambio en la rugosidad superficial que puede ser medido por perfilómetros o por medios ópticos. Estas formas de medición (perfilómetros o medios ópticos) producen mapas de elevación o rango y, por ende, son conocidos como métodos de medición de rango [4]. Lo mencionado anteriormente permite afirmar que la cantidad de desgaste está relacionada con la diferencia topográfica que se presenta antes y después del proceso de desgaste.

Este tipo de medición también tiene algunas falencias significativas. La principal de ellas es que es necesario detener el proceso de desgaste y desmontar componente para poder realizar el análisis o la cuantificación del desgaste, lo cual conlleva a realizar paradas que pueden afectar la producción y causar pérdidas de dinero, por lo que este método se usa mayormente en el laboratorio. Otra dificultad es que cuando la medición se realiza con un perfilómetro de contacto es posible que al realizar el análisis de los perfiles de la superficie afecte la superficie analizada. Además, este tipo de medición es sensible a las vibraciones, por lo cual se debe realizar en un lugar libre de interferencias [20].

1.2.2 Métodos indirectos. En esta sección se describirán algunos metodos de medición indirecta. Como su nombre lo indica estos metodos no requieren contacto directo con la superficie analizada, es decir, se puede realizar la medición sin afectar la superficie del elemento desgastado. Los métodos que se expondrán en esta sección son: ferrografía, análisis por vibraciones y análisis de imagen.

- ✓ Ferrografía. La ferrografía es una técnica usada en la detección y monitoreo del desgaste. Básicamente, en este método se realiza la recolección sistemática de muestras de aceite de una máquina lubricada con dicho fluido. El método identifica, aísla y clasifica las partículas de desgaste de las piezas de la máquina [21].

La mayoría de los elementos en una máquina están hechos de acero. Por lo tanto, se desarrollaron métodos de clasificación magnética, básicamente se usan imanes con el fin de separar las partículas de desgaste ferromagnéticas de las que no lo son. Luego de esto, tanto las partículas ferromagnéticas como las que no lo son, sometidas a diversos análisis. Para realizar dichos análisis los sólidos encontrados en el aceite son depositados sobre un portaobjeto de vidrio, el portaobjeto es examinado bajo un microscopio para analizar las partículas de desgaste por su tamaño, concentración, composición, morfología y condición de la superficie, de esta manera se puede señalar el componente que se está desgastando, cómo avanza el proceso de desgaste y, a menudo, la causa u origen de dicho proceso [21].

Este método posee varias falencias. La principal es que solo aplica para maquinas lubricadas, además de esto, es necesario detener el proceso de desgaste para obtener las muestras de lubricante necesarias para desarrollar los análisis. Otra dificultad es que los analisis de las particulas presentes en el lubricante son costosos, además el procedimiento de la prueba es lento y requiere de las habilidades de un analista bien entrenado [21].

- ✓ Análisis por vibraciones. Las vibraciones son un factor primordial en el análisis del desgaste en muchas máquinas, partes de máquinas, estructuras, vehículos, motores, etc. Dichas vibraciones pueden causar grandes perturbaciones y daños, pero en el caso específico de este método de medición las vibraciones pueden usarse para detectar y monitorear un proceso de desgaste [22]. La medición por vibraciones se puede realizar de dos maneras. La primera es por medio de un acelerómetro piezoeléctrico (sensores diseñados para medir vibraciones de baja a alta frecuencia)

y la otra por medio del uso de micrófonos omnidireccionales. La medición de vibraciones por medio de un acelerómetro consiste básicamente en recopilar señales de vibración del elemento o máquina a analizar sin que el proceso de desgaste haya iniciado, luego recopilar señales de vibración periódicamente mientras el proceso de desgaste se lleva a cabo y compararlas entre ellas. Es importante resaltar que el acelerómetro piezoeléctrico se debe adaptar al elemento o máquina que se desea analizar. Para procesar las señales de vibración se emplea el algoritmo conocido como densidad espectral de potencia (PSD). Por medio de este procesamiento de la señal de vibración es posible saber que elemento es el que se está desgastando y cómo evoluciona el proceso de desgaste, dado que cada elemento produce señales de vibración únicas [23].

La principal desventaja de este tipo de análisis es que el acelerómetro es altamente sensible a las vibraciones externas, por ende, debe estar aislado para no inducir errores en la medición [23]. El otro tipo de medición se basa en la premisa de que toda señal de vibración genera una emisión acústica. Este es un tipo de medición menos invasiva pues, a diferencia del caso anterior, no es necesario adaptar ningún instrumento de medición al elemento que se desea analizar, ya que basta con la utilización de micrófonos omnidireccionales para captar las emisiones acústicas causadas por las vibraciones. Estas emisiones acústicas al igual que las vibraciones son únicas y características de cada elemento de una máquina [23]. Este tipo de medición es sensible al ruido ambiental de fondo, lo cual es una gran desventaja dado que dicho ruido es difícil de aislar [23].

- ✓ **Análisis de imagen.** Se han realizado estudios enfocados al análisis de superficies por medios computacionales (técnicas de visión artificial) [4, 24, 25]. Estos estudios han estado dirigidos a intentar automatizar y crear herramientas de apoyo para hacer el análisis y la inspección de superficies desgastadas, simplificando de esta manera el trabajo que conlleva realizar dichas inspecciones. Básicamente, lo que se busca por medio de estas técnicas es analizar la rugosidad o la textura de la superficie por medio del procesamiento de imágenes y las técnicas de visión artificial [24]. Hay varias técnicas para realizar el procesamiento de imágenes, a continuación, se explicarán brevemente dos de esas: El análisis fractal y el aprendizaje de máquina (machine learning) que es la técnica que se usó en este trabajo.

El análisis fractal es un método que ha sido frecuentemente usado en trabajos de

Investigación que buscan detectar o monitorear procesos de desgaste [26, 6]. En este tipo de medición básicamente se tiene que definir la dimensión fractal, la cual es una firma o caracterización numérica de la complejidad de un proceso. Para llevar a cabo un análisis fractal es necesario asignar valores numéricos a un conjunto de parámetros. En el caso de la detección y monitoreo del desgaste se debe asignar dichos valores numéricos a las características morfológicas de la superficie desgastada y así crear un conjunto de ecuaciones (generalmente) que permitan modelar y a su vez monitorear el proceso de desgaste [27].

Hay diferentes técnicas de determinación de superficies fractales, algunos ejemplos son dimensión Fourier, dimensión Kolmogorov, Korcak, Minkowski, entre otras. Cada una de estas técnicas tiene sus ventajas y desventajas asociadas [28], pero como tal la detección y monitoreo del desgaste por análisis fractal tiene sus dificultades generales. Una dificultad de este método de medición es que necesita imágenes de altas magnificaciones y calidad para poder definir la dimensión fractal (imágenes de SEM, por ejemplo). La desventaja más significativa de este método es que es necesario detener el proceso de desgaste para poder realizar los análisis, además de que requiere personal con habilidad y conocimiento para poder comprender y analizar los resultados arrojados por las mediciones [27].

El aprendizaje de máquina es una técnica poco usada en esta área del conocimiento. Por medio del trabajo realizado en este proyecto, se encontró la forma de crear un algoritmo (código fuente) de programación capaz de diferenciar entre los regímenes moderado y severo del desgaste abrasivo cuando se analizaron imágenes de microscopía electrónica de barrido (SEM) de superficies desgastadas. La principal ventaja de este método es que se puede adaptar para realizar las mediciones en línea, es decir, no es necesario detener el proceso de desgaste para realizar la medición y el monitoreo del mismo. Más adelante se explicará la metodología usada y los resultados obtenidos.

2. OBJETIVOS

2.1. OBJETIVO GENERAL

Desarrollar una metodología computacional que permita la detección y el monitoreo de los regímenes de desgaste por medio del análisis de imagen y la aplicación de técnicas de aprendizaje máquina.

2.2. OBJETIVOS ESPECÍFICOS

1. Desarrollar las habilidades y competencias necesarias para crear el código fuente, mediante el uso de los softwares Python y OpenCV.
2. Caracterizar las imágenes de superficies desgastadas obtenidas en ensayos de desgaste por abrasión realizados en el laboratorio mediante técnicas de análisis de imagen.
3. Aplicar y optimizar las técnicas de aprendizaje de máquina que permitan diferenciar los regímenes de desgaste en las superficies analizadas.

3. METODOLOGÍA

3.1. REVISIÓN BIBLIOGRÁFICA

Se realizó una consulta constante en la base de datos disponible en la universidad con el propósito de identificar estudios recientes relacionados al tema de investigación. La búsqueda y recuperación de información se enfocó en libros, artículos de revisión bibliográfica (Review papers), tesis de doctorado y artículos de investigación que contenían información referente a la detección y monitoreo del desgaste.

3.2. SELECCIÓN Y CLASIFICACIÓN DE IMÁGENES

Las imágenes seleccionadas para el análisis en este trabajo se obtuvieron de una investigación sobre el efecto de la dureza de las partículas abrasivas en la transición del régimen de desgaste moderado – severo de algunas fundiciones de hierro [1]. En esta investigación se llevaron a cabo pruebas de desgaste abrasivo variando tanto la dureza de los materiales de prueba (H) como de las partículas abrasivas (H_A). La información detallada de las pruebas de desgaste y los materiales usados se puede encontrar en el artículo de Coronado y colaboradores [1]. En la Tabla 1 y Tabla 2 se muestra la descripción y la dureza de los materiales de prueba y de las partículas abrasivas, respectivamente.

Tabla 1. Descripción y dureza de los materiales de prueba [1].

Símbolo	Materiales de prueba	Dureza	
		[HV_{98N}]	[MPA]
Fa	FB Matriz austenítica	694 ±16	3670 ±85
Fm	FB Matriz martensítica	777 ±14	4109 ±74
F14	FB 13,8 % Cr	966 ±30	5108 ±159
F24	FB 24,4 % Cr	1062 ±27	5616 ±143
M	FA	493 ±8	2607 ±42

FB: Fundición blanca, FA: Fundición atruchada

Durante los ensayos de abrasión, los materiales de prueba se frotaron contra cada una de las partículas abrasivas. En dichas pruebas se obtuvieron varias relaciones de dureza (H_A/H). La tasa de desgaste en función de la relación de dureza se puede observar en la Figura 3. En este gráfico, se distinguieron dos regiones principales correspondientes a los regímenes de desgaste moderado y severo. En el régimen de desgaste moderado,

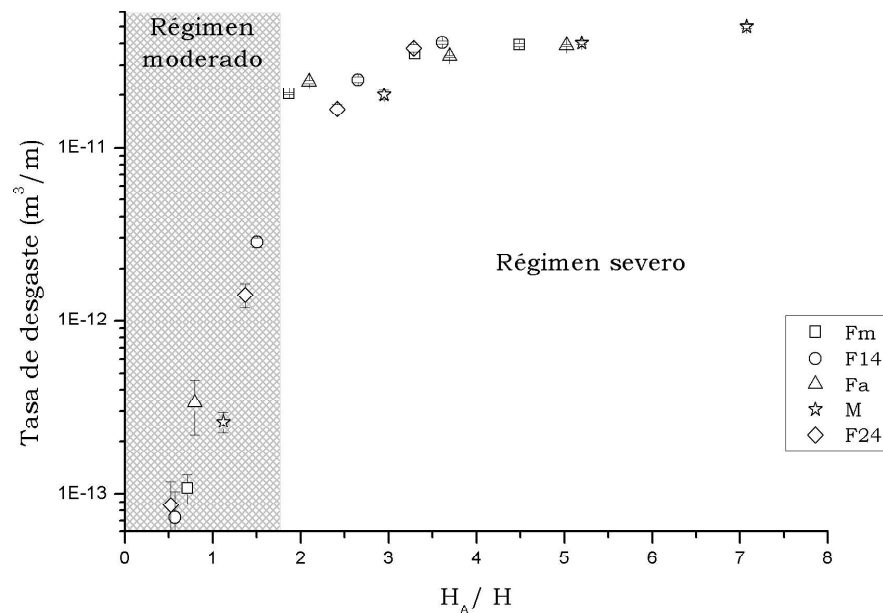
se produjeron valores bajos de la tasa de desgaste cuando la relación H_A/H estaba por

Tabla 2. Descripción y dureza de las partículas abrasivas [1].

Partícula abrasiva	Dureza	
	[$HV_{0,98N}$]	[MPa]
Vidrio	522 ± 26	2920 ± 138
Granate	1453 ± 85	7687 ± 450
Al_2O_3	2563 ± 124	13559 ± 656
SiC	3487 ± 322	18447 ± 1703

debajo de 1.9 [1]. Se debe observar que, en la región de desgaste moderado, se logró una mayor tasa de desgaste al aumentar la relación H_A/H . Sin embargo, los valores más altos de la tasa de desgaste en la región de desgaste moderado se consideraron como una tasa de desgaste baja. Cuando los valores de la relación H_A/H fueron superiores a 1.9, se aprecia una región donde actuó el régimen de desgaste severo. En esta región, se observó una tasa de desgaste aproximadamente constante para todas las condiciones.


Figura 3. Tasa de desgaste de los materiales de muestra en función de la relación de dureza (H_A/H) [1].



Se seleccionaron, clasificaron y etiquetaron un total de 50 imágenes SEM de superficies desgastadas de seis de las relaciones de dureza, de acuerdo con los dos regímenes de desgaste. 29 imágenes correspondieron a las condiciones de prueba que exhibieron desgaste severo y 21 imágenes se asociaron a las condiciones en las cuales se observó el régimen moderado. En la Figura 4 se muestran las imágenes SEM correspondientes


a algunas de las condiciones de prueba, donde se pueden apreciar las principales diferencias entre las características superficiales producidas en ambos regímenes de desgaste. El régimen moderado generó un desgaste leve con poca cantidad de surcos superficiales, mientras que las superficies desgastadas en el régimen severo presentaban superficies rugosas con presencia de deformación plástica, formación de microgrietas y surcos más profundos [1].

Figura 4. Imágenes SEM de las superficies desgastadas para las condiciones F14-Vidrio (a), Fa-Vidrio (b), F24-Granate (c), M-SiC (d), M-Granate © y Fm-Granate (f).




(a)

F14-Vidrio: Desg. Moderado (b) Fa-Vidrio: Desg. Moderado



© F24-Granate: Desg. Moderado (d) M-SiC: Desg. Severo



© M-Granate: Desg. Severo

(f) Fm-Granate: Desg. Severo

3.3. APLICACIÓN DEL HISTOGRAMA DE GRADIENTE ORIENTADO (HOG)

La severidad del desgaste de las superficies se puede asociar con patrones de gradiente no uniformes en las imágenes capturadas (ver ejemplos de imágenes SEM en la Figura 4). Sin embargo, las imágenes SEM asociadas al desgaste moderado y severo contienen una gran variedad de patrones de gradiente a lo largo de la superficie, y una clasificación automática de tal condición podría ser difícil a partir de cuantificaciones generales y globales. Por ejemplo, la cuantificación general del gradiente en la imagen completa omite la descripción local de los gradientes, y dicha descripción podría ser fundamental para entender el grado de severidad del desgaste. En este trabajo, se realiza una cuantificación de gradiente local mediante el cálculo de un conjunto de histogramas orientados a lo largo de las imágenes, lo que permite una descripción local de las superficies.

El cálculo del HOG comienza dividiendo una imagen en un conjunto de celdas rectangulares con tamaño $\mathbf{ci} = c_h \times c_b$ (h = ancho y b = alto). Luego, se calcula un histograma local de gradientes de forma independiente en cada una de estas celdas ci . Después, el histograma se define como un conjunto de bins que codifica las orientaciones en las celdas, que a su vez se ponderan según su norma de gradiente respectiva. En este caso, una superficie lisa con desgaste moderado podría representarse como un histograma uniforme con igual probabilidad para todas las orientaciones de gradiente. En contraste, las celdas locales (ci) que capturan las características del desgaste severo en la superficie están representados por histogramas asimétricos que representan la falta de uniformidad de la superficie. Finalmente, se podría lograr un análisis regional de un conjunto de celdas vecinas agrupando los histogramas respectivos y realizando una normalización de bloque con respecto al número total de celdas.

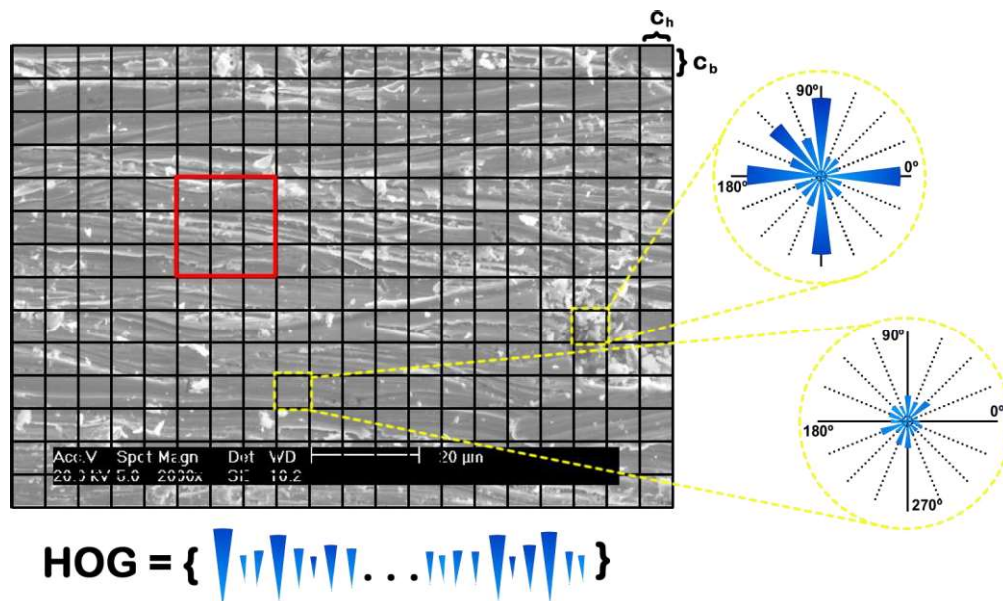
La configuración HOG completa se ilustra en la Figura 5. A partir de ahora, la notación p - cq - br se tomará para expresar una configuración HOG donde p hace referencia a las orientaciones, q al tamaño de las celdas y r a las celdas agrupadas en el bloque normalizado. El tamaño de las celdas, el número de orientaciones y el número de celdas agrupadas que se deben normalizar constituyen los parámetros principales del descriptor HOG para capturar patrones de desgaste en imágenes de SEM. El descriptor HOG se resume como la concatenación de todos los depósitos de histogramas calculados, como x_1, x_2, \dots, x_n .

Este descriptor HOG se ha utilizado con éxito en muchos contextos y aplicaciones de la visión por computadora como la detección de objetos, el reconocimiento de personas, entre muchos otros. Esencialmente, este descriptor es capaz de describir de manera

sólida cualquier configuración geométrica mediante el uso de estadísticas de ocurrencia de los gradientes en regiones locales. La descripción local de los histogramas de gradiente y la normalización regional en bloque logran una descripción global densa de los patrones que están presentes en una imagen en particular.

En este caso particular, la severidad del desgaste se puede describir exitosamente usando el descriptor HOG, ya que los patrones severos “anormales” se destacan en histogramas no uniformes capturados a lo largo de la secuencia.

Figura 5. Ejemplo ilustrativo del cálculo del descriptor HOG sobre una imagen SEM.



Cada región de la cuadrícula es una celda calculada con tamaño $c_b \times c_h$. En cada una de estas celdas se calcula un histograma orientado. Como se ilustra en la imagen, en las regiones donde el desgaste es moderado, el histograma correspondiente es uniforme con una magnitud baja en cada uno de los contenedores. A diferencia de las regiones severas, donde se evidencia que los histogramas no son uniformes. Un conjunto de parches b_n (cuadrado rojo) se unen para llevar a cabo una normalización global. Finalmente, el descriptor de HOG corresponde al conjunto de bandejas orientadas completas calculadas a lo largo de la imagen.

3.4. IMPLEMENTACIÓN DE LOS CLASIFICADORES

En ese paso se implementó un proceso de clasificación automática para etiquetar cada imagen según el grado de desgaste que esta posee. Esta tarea de clasificación comprende el etiquetado automático y de dos clases diferentes de superficies desgastadas: severas y moderadas, expresadas como $y = \{0, 1\}$, respectivamente. Para

hacerlo, cada imagen se representa con un vector descriptor HOG como $\mathbf{x} = \{x_1, x_2, \dots, x_n\}$, donde cada x_i es una función bin resultante del descriptor. Luego se usa un conjunto de m descriptores HOG $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m$ para construir un modelo de entrenamiento que permita establecer límites entre las dos categorías con algún margen error. La tarea de clasificación para una muestra particular se puede modelar como la probabilidad de pertenecer a una clase y_i dado un descriptor HOG particular. En tal caso, la muestra que se va a clasificar se proyecta en un espacio entrenado y la etiqueta más cercana (o similar) se le asigna.

En la literatura hay varios algoritmos para realizar dicha clasificación que consideran diferentes suposiciones para dividir el espacio de las características y establecer límites entre las clases entrenadas [29, 30]. La efectividad de tales metodologías depende del tamaño, la calidad y la naturaleza de los datos. La clasificación de desgaste representada en los patrones de gradiente puede ser muy variable, y gran parte de las regiones se pueden compartir en ambos regímenes de desgaste (moderado y severo). En este trabajo consideramos tres clasificadores, los cuales se describen a continuación:

3.4.1 Gaussian Naive Bayes (Gauss). Este clasificador es uno de los algoritmos más simples y rápidos para realizar tareas de clasificación bajo una suposición sólida de independencia condicional entre las características del descriptor $\{x_1, x_2, \dots, x_n\}$. Luego, la distribución condicional de una etiqueta particular dado el descriptor HOG se puede modelar como se muestra en la Ecuación 1:

$$P(y_k = 0 | x_1, x_2, \dots, x_n) \propto P(y_k = 0) \prod_{i=1}^n P(x_i | y_k = 0) \quad (1)$$

Donde cada x_i corresponde a una función particular bin en el descriptor HOG y y_i es la etiqueta (moderado / severo). También en el modelo de entrenamiento, asumimos que cada una de las características x_i está asociada con la clase particular y_i de acuerdo con una distribución gaussiana, como se expresa en la Ecuación 2:

$$P(x_i | y_i = 0) = N(\mu_{x_i}, \sigma_{x_i}) \quad (2)$$

Este clasificador constituye una alternativa rápida y eficiente que codifica de forma independiente cada una de las características del descriptor.

3.4.2 Decision Tree (DT). Una alternativa considerada fue la clasificación de imágenes de desgaste bajo la implementación de un algoritmo de árbol computacional no paramétrico. En este caso, la conjunción de las características HOG $\{x_1, x_2, \dots, x_n\}$ representa las ramas de un árbol de aprendizaje particular y las etiquetas $y = \{0, 1\}$ están representadas en las hojas.

En este caso, se asume que cada una de las características de HOG tiene un dominio discreto y que el árbol de aprendizaje se obtiene dividiendo recursivamente el dominio de características, de manera que las mismas etiquetas se agrupan en los mismos grupos. Luego, a partir de un conjunto de descriptores HOG de entrenamiento $\{\mathbf{x}_j\}_{j=1..m}$ con las correspondientes anotaciones de etiqueta de severidad $y = \{0, 1\}$ se define como un conjunto de divisiones candidatas como $\theta = (j, \tau_m)$ con respecto a la característica HOG j y una partición de umbral particular τ_m . En cada nodo, Q del árbol, por lo tanto, se define una partición $Q_{left}(\theta)$ y $Q_{right}(\theta)$. A partir de dicha división, se introduce un término “Gini impurity” que mide la frecuencia con la que un elemento elegido al azar se etiquetaría incorrectamente en un nodo específico $G(Q, \theta)$. Por lo tanto, los parámetros se seleccionan siguiendo una regla de minimización, como se define en la Ecuación 3:

$$\theta^* = \arg \min_{\theta} G(Q, \theta) \quad (3)$$

Una de las principales ventajas de este clasificador es la descripción de los resultados y la posibilidad de comprender visualmente la decisión de la etiqueta a través de las ramas de características. Sin embargo, un árbol simple puede ser insuficiente para aprender toda la variabilidad de los datos y la predicción puede variar según el número de muestras tomadas para construir el árbol.

3.4.3 Random Decision Forest (RaF). En este trabajo también se analizó el valor de rendimiento de la predicción automática del desgaste mediante el uso de un conjunto de clasificadores de árbol de decisión agrupados en una estrategia de aprendizaje conjunto llamada Random Decision Forest. Este clasificador supera algunos problemas de sensibilidad de los árboles de decisión al calcular diferentes estructuras de árbol y tomar decisiones de modo sobre estos árboles computados.

En general, los árboles de decisión (DT) podrían tener un sesgo bajo y una varianza muy alta en los resultados, dependiendo en gran medida de los parámetros de inicialización y las características utilizadas en el proceso de aprendizaje. En la estrategia de bosques aleatorios, un conjunto de algoritmos DT independientes se entrena en diferentes partes

del espacio de características HOG para reducir la variabilidad en la predicción. Para ello, se implementa una estrategia de agregación de Bootstrap, que consiste en seleccionar aleatoriamente un conjunto de funciones de entrenamiento HOG $\{x_1, x_2, \dots, x_n\}$ para crear un árbol de decisión particular f_b . Este proceso se realiza varias veces para obtener B árboles diferentes con la capacidad de realizar la predicción de la etiqueta de severidad y_i a partir de un conjunto de características HOG. La predicción final se puede realizar promediando las predicciones de árboles individuales, o tomando el voto mayoritario como se expresa en la Ecuación 4:

$$\hat{y} = \frac{1}{B} \sum_{b=1}^B f_b \wedge \hat{y} = \arg \max\{f_1, \dots, f_B\} \quad (4)$$

Esta estrategia en muchos de los casos resulta ser la más precisa para obtener predicciones automáticas sobre grandes conjuntos de datos de imágenes de entrenamiento.

3.5 VALIDACIÓN ESTADÍSTICA

Teniendo en cuenta que la tarea de clasificación depende del número de muestras de entrenamiento, en este documento se utilizó una estrategia estadística de validación cruzada para analizar el rendimiento de la metodología propuesta en un número diferente de muestras. Dicho análisis se amplió para observar el rendimiento del descriptor HOG utilizando una configuración diferente, por ejemplo, el tamaño de la celda, el número de orientaciones y el número de celdas utilizadas para normalizar el descriptor. Además, la validación cruzada se evaluó sobre los diferentes clasificadores implementados.

La validación cruzada implementada fue la estrategia de k – fold, en la que todo el conjunto de datos se divide iterativamente en dos subconjuntos complementarios. En cada división, un subconjunto se llama conjunto de entrenamiento y el otro se denomina conjunto de prueba para validar el enfoque particular. Dicha partición se realiza en varias rondas para reducir la variabilidad en los resultados y caracterizar adecuadamente el rendimiento predictivo del modelo.

En particular, para estos experimentos, todo el conjunto de datos inicialmente se baraja aleatoriamente y luego se divide en submuestras iguales de k . Luego, los subconjuntos $k-1$ se usan para construir un modelo de entrenamiento y el subconjunto restante se usa para probar la estrategia. Este proceso se repite k veces para garantizar todas las muestras posibles en los subconjuntos de entrenamiento y prueba. Finalmente, se calcula un promedio sobre todos los k experimentos para obtener la precisión del enfoque particular. En una configuración particular de $k = n$, con n el número total de imágenes, obtenemos

una *leave-one-out cross-validation* en la que el mayor número de muestras son usadas para construir el modelo de entrenamiento y solo se prueba una imagen en cada ronda. Una precisión en la predicción (en %) fue el criterio principal utilizado para evaluar el rendimiento del cálculo del descriptor HOG junto con los modelos de clasificadores.


4. RESULTADOS Y DISCUSIÓN

4.1 DESCRIPTOR HOG

Los resultados del cálculo del HOG con imágenes de prueba donde se exhibe los regímenes de desgaste moderado y severo se muestran en la Figura 6. Esta figura presenta las imágenes de superficies desgastadas en el régimen de desgaste moderado (a) y severo (b), junto con los resultados HOG correspondientes a las configuraciones de $4-c16-b1$ (c) y $32-c64-b1$ (d). Inicialmente, se podría notar que los resultados de HOG son más uniformes en la imagen de la superficie donde actuó el régimen de desgaste moderado que en la imagen del régimen de desgaste severo. Esto es una consecuencia de las pocas variaciones morfológicas que se encuentran en la superficie desgastada en el régimen moderado. Por el contrario, la imagen desgastada en el régimen severo exhibe características de superficie más notables, como los bordes, que dan como resultado un patrón particular obtenido en el cálculo del HOG respectivo.


Como consecuencia de la variación en los parámetros HOG de orientación y tamaño de la celda, se pueden observar algunas diferencias entre los resultados HOG para ambas configuraciones. En primer lugar, podemos notar la mayor cantidad de celdas pequeñas en la configuración de $4-c16-b1$, que permite identificar con más detalle las características de la superficie en la imagen. Por otro lado, la cantidad de orientaciones HOG no parece tener un efecto marcado. Esto podría deberse a que las superficies desgastadas tienen un componente direccional fuerte, ya que la prueba de desgaste por abrasión establece una dirección de deslizamiento específica. Debe mencionarse que la leyenda de SEM está presente en todas las imágenes, y por ende no genera ningún efecto en el análisis.

Figura 6. Resultados HOG para las imágenes de superficies desgastadas en el régimen de desgaste moderado y severo con diferentes configuraciones.




(a) Desgaste moderado

(b) Desgaste severo



(c) HOG con configuración 4 – $c16 - b1$




(1) HOG con configuración 32 – $c64 - b1$

4.2 ANÁLISIS DE LA VALIDACIÓN CRUZADA DE LOS CLASIFICADORES

Se realizó una validación cruzada de k – fold en el conjunto de clasificadores usando diferentes configuraciones HOG. Los resultados de la validación cruzada de los clasificadores en términos de precisión media (%) para las diferentes combinaciones de parámetros HOG se presentan en la Figura 7.

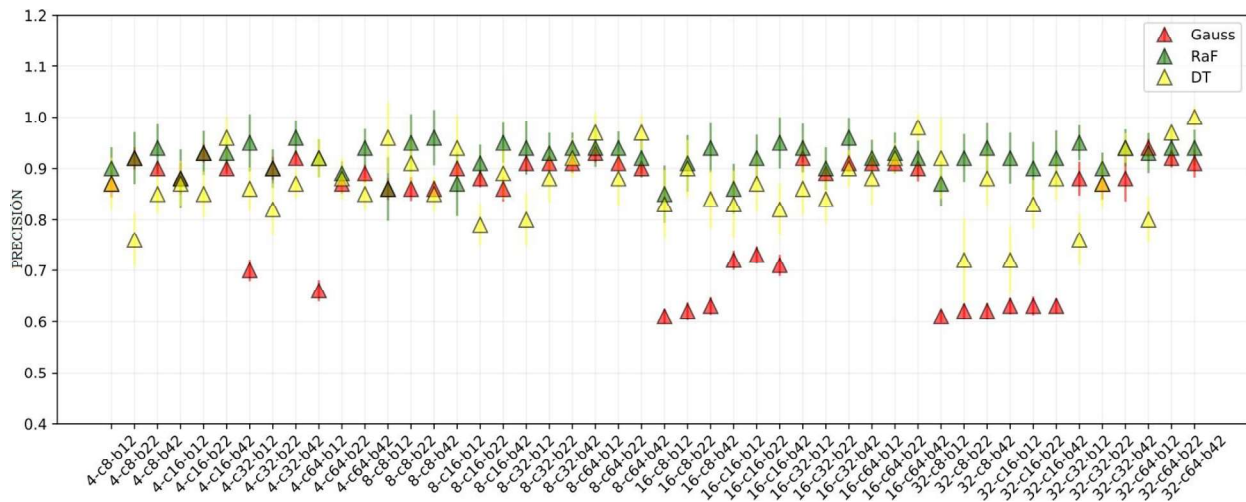
Desde un punto de vista general, todos los clasificadores tuvieron un comportamiento sobresaliente ya que predicen muy bien el tipo de desgaste que exhibe una imagen en particular. En otras palabras, los clasificadores pueden reconocer una imagen que muestra características pertenecientes al régimen de desgaste moderado o severo con una precisión de aproximadamente el 80 %. El clasificador RaF da como resultado los valores de precisión más estables. Sin embargo, el clasificador DT alcanzó valores más altos cercanos al 95 % en algunas configuraciones de HOG. Debe tenerse en cuenta que el clasificador DT mostró un rendimiento inestable debido a la alta dispersión de los valores de precisión. Por otro lado, el clasificador Gauss tuvo un comportamiento estable, pero en varias configuraciones mostró valores bajos de precisión.

Figura 7. Resultados de los valores de precisión media de los clasificadores para diferentes configuraciones de parámetros HOG



Los valores máximos de precisión para las mismas configuraciones de parámetros HOG se muestran en la Figura 8. Se observó un comportamiento muy similar entre los valores máximo y medio de precisión. Debe destacarse que la mayor parte de los valores máximos de RaF son mayores que 90 %, lo que da un resultado confiable de la capacidad de este clasificador. Al mismo tiempo, también se puede alcanzar una precisión del 100 % con el clasificador DT, pero con una única combinación determinada de 32 – c64 – b42 en los parámetros HOG.

Figura 8. Resultados de los valores de precisión máxima de los clasificadores para diferentes configuraciones de parámetros HOG.



Para analizar mejor el efecto de los parámetros HOG r (cantidad de celdas agrupados) y q (tamaños de parches) en los procesos de clasificación, algunos resultados de precisión se presentan en la Tabla 3 y la Tabla 4, respectivamente. Inicialmente, en la Tabla 3 se muestran los resultados en la precisión de los clasificadores para tres configuraciones HOG que varían el número de celdas agrupadas. Allí, se puede observar el mejor rendimiento del clasificador DT, que obtuvo las más altas precisiones en valores medios y máximos. De hecho, para los histogramas de 32 orientaciones, con una dimensión de celda de 64×64 y utilizando 42 celdas ($32-c64-b42$), se produjo una precisión máxima de 100 %.

Tabla 3. Resultados de precisión (%) para los clasificadores con diferentes orientaciones HOG.

Clasificador	% de precisión con diferentes orientaciones HOG					
	8-c64-b42		16-c64-b42		32-c64-b42	
	Media	Max.	Medias	Max.	Media	Max.
Gauss	0,88±0,22	0.90	0,87±0,23	0.90	0,86±0,23	0.91
RaF	0,85 ± 0,23	0.92	0,85±0,24	0.92	0,86 ± 0,23	0.94
DT	0,91 ± 0,18	0.97	0,94±0,15	0.98	0,96 ± 0,13	1

En la Tabla 4 se resume el resultado obtenido para cada clasificador cambiando el tamaño de celda q en la imagen y calculando el mismo número de histogramas de bloque. En


general, para los clasificadores de Gauss y DT, las celdas más grandes aumentan la descripción de los patrones de gradiente y logran una mejor precisión de clasificación. El rendimiento de RaF es estable para todas las configuraciones de tamaño de celda.

Tabla 4. Resultados de precisión (%) para los clasificadores con diferentes tamaños de celda HOG.

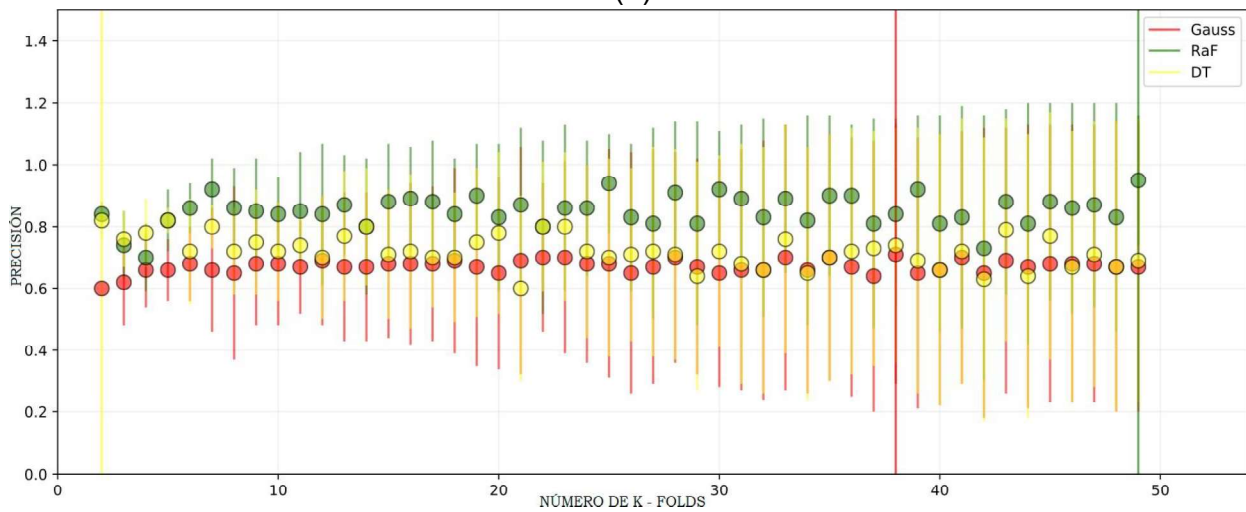
Clasificador	% de precisión con diferentes tamaños de celda HOG					
	16-c16-b42		16-c32-b42		16-c64-b42	
	Media	Max.	Media	Max.	Media	Max.
Gauss	0,67±0,32	0.71	0,87±0,23	0.91	0,87±0,23	0.90
RaF	0,85 ± 0,24	0.95	0,87±0,23	0.96	0,85 ± 0,24	0.92
DT	0,72 ± 0,29	0.82	0,83±0,25	0.90	0,94 ± 0,15	0.98

En la Figura 9 se muestra el efecto de la cantidad de k – folds (iteraciones) en los valores de precisión para los tres modelos clasificadores en determinadas configuraciones HOG. Además, se muestran las barras de error y los valores máximos de precisión (líneas verticales) para cada clasificador. Como se puede ver en la Figura 9 (a) en la configuración 16 – c64 – b42 todos los modelos de clasificadores tuvieron un comportamiento estable y la desviación estándar aumentó con el número de k – folds (iteraciones). En general, los valores más altos de precisión se obtuvieron para el clasificador DT. Se debe tener en cuenta que los valores máximos de precisión se obtuvieron a valores bajos de k – fold. Los resultados muestran que una validación cruzada con bajos valores de k – fold, para una determinada configuración HOG, podría llevar a adquirir una dispersión mínima de datos y valores máximos de precisión para los tres modelos de clasificador. Esto sería ventajoso en términos de costo computacional. Por otro lado, los resultados de precisión para los modelos de clasificador con una configuración HOG de 16 – c16 – b42, permiten conocer el efecto de disminuir el tamaño de la celda mientras se mantienen constantes los otros parámetros del HOG. Inicialmente, se puede observar cómo en esta configuración se alcanzan los mejores resultados con el clasificador RaF, pero con precisiones más bajas que las obtenidas por el clasificador DT en la configuración HOG anterior. Nuevamente, a valores bajos de k – fold se reduce la desviación estándar para todos los modelos. Sin embargo, en esta configuración HOG, los valores máximos de precisión para los modelos de Gauss y RaF se adquirieron a valores altos de k – fold.

Figura 9. Resultados de precisión en términos del número de k – fold para las configuraciones 16-c64-b42 (a) y 16-c16-b42 (b).



(a)



(b)

5. CONCLUSIONES

1. Este trabajo logró el reconocimiento y clasificación automática de los regímenes de desgaste abrasivo a partir de las características geométricas (gradientes) presentes en las imágenes de superficies desgastadas. La estrategia computacional desarrollada fue capaz de indexar la severidad del desgaste de las imágenes de superficies desgastadas.
2. El rendimiento del clasificador RaF presentó una alta efectividad para describir el régimen de desgaste presente en las imágenes SEM de superficies desgastadas. Dicha efectividad se ve representada con valores medios de precisión de predicción superiores al 80 % en la mayor parte del cálculo de HOG.
3. El RaF mostró el comportamiento más consistente sin considerar la configuración de HOG, pero en algunas configuraciones de HOG en particular fue superado por el clasificador DT. En dichas configuraciones el DT tuvo un comportamiento sobresaliente en el que eventualmente se podría predecir el tipo de desgaste de una imagen con una alta precisión. Sin embargo, en general el DT exhibió un rendimiento irregular con algunos valores medios y máximos de precisión bajos para algunas configuraciones HOG.

6. RECOMENDACIONES

1. Desde el punto de vista del trabajo futuro, es necesario utilizar imágenes obtenidas a bajos aumentos (por ejemplo, mediante una cámara de video) para realizar el análisis de imágenes de superficies desgastadas. Esto sería fundamental para desarrollar un sistema de detección en línea que permita tener un reconocimiento automatizado de los regímenes de desgaste abrasivo en la superficie de las piezas de una máquina. Este análisis podría aplicarse también al desgaste por deslizamiento de los metales, donde las superficies desgastadas por la acción de los regímenes de desgaste severo y moderado muestran características bien definidas [16]. De hecho, la estrategia computacional aquí propuesta también podría aplicarse en otros tipos de desgaste, siempre y cuando se observen transiciones entre diferentes regímenes de desgaste.

REFERENCIAS BIBLIOGRÁFICAS

- [1] J.J CORONADO, S. A. RODRÍGUEZ, AND A. SINATORA. Effect of particle hardness on mild-severe wear transition of hard second phase materials. *Wear*, 301(1-2):82–88, 2013.
- [2] K. HOLMBERG. Reliability aspects of tribology. *Tribology International*, 34(12):801–808, 2001.
- [3] K.H. ZUM-GAHR. *Microstructure and wear of materials*. Elsevier, 1987.
- [4] J. ZHANG. *Detection and monitoring of wear using imaging methods*. Doctoral thesis, University of Twente, 2006.
- [5] I. HUTCHINGS AND P. SHIPWAY. *Tribology – Friction and wear of engineering materials*. Butterworth-Heinemann, Elsevier, second edition, 2017.
- [6] J. ZHANG, P. REGTIEN, AND M. KORSTEN. Monitoring of dry sliding wear using fractal analysis. *10th IMEKO TC10 International Conference on Technical Diagnostics*, pages 1–8, 2005.
- [7] A. ABOUEL-KASEM, M. AL-BUKHAITI, K. M. EMARA, AND S. AHMED. Fractal characterization of slurry eroded surfaces at different impact angles. *Journal of Tribology*, 131(3):31601, 2009.
- [8] M.C. ISA, N.H.N. YUSOFF, HASRIL NAIN, MOHD SUBHI DIN YATI, M.M. MUHAMMAD, AND IRWAN MOHD NOR. Ferrographic Analysis of Wear Particles of Various Machinery Systems of a Commercial Marine Ship. *Procedia Engineering*, 68:345–351, Jan 2013.
- [9] F. E. LOCKWOOD AND R DALLEY. Lubricant analysis. *ASM International, ASM Handbook*.18:299–312, 1992.
- [10] M.D. HANEEF, R.B. RANDALL, W.A. SMITH, AND Z. PENG. Vibration and wear prediction analysis of IC engine bearings by numerical simulation. *Wear*, 384-385:15–27, aug 2017.
- [11] F. GIUSTI, M SANTOCHI, AND G TANTUSSI. On-line sensing of flank and crater wear of cutting tools. *CIRP Annals – Manufacturing Technology*, 36(1):41–44, 1987.
- [12] S. KURADA AND C. BRADLEY. A machine vision system for tool wear assessment. *Tribology International*, 30(4):295–304, 1997.

- [13] A. D. H. THOMAS, T DAVIES, AND A R LUXMOORE. Computer image analysis for identification of wear particles. *Wear*, 42:213–226, 1991.
- [14] Z. PENG AND T.B. KIRK. Computer image analysis of wear particles in three-dimensions for machine condition monitoring. *Wear*, 223(1-2):157–166, 1998.
- [15] S. DUTTA, S. K. PAL, S MUKHOPADHYAY, AND R SEN. Application of digital image processing in tool condition monitoring: A review. *CIRP Journal of Manufacturing Science and Technology*, 6(3):212–232, 2013.
- [16] C.C VIÁFARA AND A SINATORA. Influence of hardness of the harder body on wear regime transition in a sliding pair of steels. *Wear*, 267(1-4):425–432, 2009.
- [17] RAYMOND G. BAYER. *Mechanical Wear Fundamentals and Testing, revised and expanded*. CRC Press, 2004.
- [18] B. AVIENT. J. GODDARD, AND H. WILMAN. An Experimental Study of Friction and Wear During Abrasion of Metals. *Proceedings of the Royal Society of London. Series A, Mathematical and Physical Sciences*, 258(1293):159–180, 1960.
- [19] J.J. CORONADO AND A. SINATORA. Effect of abrasive size on wear of metallic materials and its relationship with microchips morphology and wear micromechanisms: Part 1. *Wear*, 2011.
- [20] R. GÅHLIN AND S. JACOBSON. A novel method to map and quantify wear on a micro-scale. *Wear*, 222(2):93–102, nov. 1998.
- [21] K. BØVING. *NDE handbook: non-destructive examination methods for condition monitoring*. Elsevier, 2014.
- [22] UBAIDULLAH M., KRISHNA B. Control of vibrations using adaptive filters. *International Journal of Control Theory and Applications*, 8(3):1243–1249, 2015.
- [23] Z. MEDRANO, C. TELLO, J. GÓMEZ, AND M. VERA. Nueva metodología de diagnóstico de fallas en rodamientos en una máquina síncrona mediante el procesamiento de señales vibro-acústicas empleando análisis de densidad de potencia. *Ingeniería, Investigación y Tecnología*, 17(1):73–85, Jan 2016.
- [24] A. SRIVANI. Investigation of Surface Texture Using Image Processing Techniques. *Procedia Engineering*, 97:1943–1947, Jan 2014.

- [25] J. ZHANG AND P. REGTIEN. Illumination methods for optical wear detection. In *Proceedings of the 6th International Conference Measurement 2007*. Slovak Institute of Measurement Science, 2007.
- [26] A. A. KASEM, F.A. ALTURKI, AND S.M. AHMED. Fractal analysis of cavitation eroded surface in dilute emulsions. *Journal of Tribology*, 133(4):041403, 2011.
- [27] J. RAWERS AND J. TYLCZAK. Fractal characterization of wear erosion surfaces. *Journal of Materials Engineering and Performance*, 8(6):669–676, 1999.
- [28] J. C. RUSS. *Fractal surfaces*. Springer Science & Business Media, 2013.
- [29] N. M. NASRABADI. Pattern recognition and machine learning. *Journal of Electronic Imaging*, 16(4):49901, 2007.
- [30] R. O. DUDA, P. E. HART, AND D. G. STORK. *Pattern classification*. John Wiley & Sons, 2012.

BIBLIOGRAFÍA

ABOUEL-KASEM, M A. AL-BUKHAITI, K. EMARA, AND S. AHMED. Fractal characterization of slurry eroded surfaces at different impact angles. *Journal of Tribology*, 131(3):31601, 2009.

SRIVANI. Investigation of Surface Texture Using Image Processing Techniques. *Procedia Engineering*, 97:1943–1947, Jan 2014.

C.C VIÁFARA AND A SINATORA. Influence of hardness of the harder body on wear regime transition in a sliding pair of steels. *Wear*, 267(1-4):425–432, 2009.

J.J CORONADO, S. A. RODRÍGUEZ, AND A. SINATORA. Effect of particle hardness on mild-severe wear transition of hard second phase materials. *Wear*, 301(1-2):82–88, 2013.

J.J. CORONADO AND A. SINATORA. Effect of abrasive size on wear of metallic materials and its relationship with microchips morphology and wear micromechanisms: Part 1. *Wear*, 2011.

J. ZHANG. *Detection and monitoring of wear using imaging methods*. Doctoral thesis, University of Twente, 2006.

J. ZHANG, P. REGTIEN, AND M. KORSTEN. Monitoring of dry sliding wear using fractal analysis. *10th IMEKO TC10 International Conference on Technical Diagnostics*, pages 1–8, 2005.

J. ZHANG AND P. REGTIEN. Illumination methods for optical wear detection. In *Proceedings of the 6th International Conference Measurement 2007*. Slovak Institute of Measurement Science, 2007.

K. HOLMBERG. Reliability aspects of tribology. *Tribology International*, 34(12):801–808, 2001.

K.H. ZUM-GAHR. *Microstructure and wear of materials*. Elsevier, 1987.

HUTCHINGS AND P. SHIPWAY. *Tribology – Friction and wear of engineering materials*. Butterworth-Heinemann, Elsevier, second edition, 2017.

R. O. DUDA, P. E. HART, AND D. G. STORK. *Pattern classification*. John Wiley & Sons, 2012.

Z. PENG AND T.B. KIRK. Computer image analysis of wear particles in three dimensions for machine condition monitoring. *Wear*, 223(1-2):157–166, 1998.