

**CUANTIFICACIÓN Y PREDICCIÓN DE MECANISMOS DE DESGASTE EN  
IMÁGENES DE SUPERFICIES DEGRADADAS**

**BRAYAN CAMILO VALENZUELA RINCÓN**

**UNIVERSIDAD INDUSTRIAL DE SANTANDER  
FACULTAD DE INGENIERÍAS FÍSICOMECÁNICAS  
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA  
BUCARAMANGA**

**2020**

**CUANTIFICACIÓN Y PREDICCIÓN DE MECANISMOS DE DESGASTE EN  
IMÁGENES DE SUPERFICIES DEGRADADAS**

**BRAYAN CAMILO VALENZUELA RINCÓN**

**Una tesis presentada en cumplimiento de los requisitos para el grado de:  
Ingeniero de Sistemas e Informática**

**Director:**

**Fabio Martínez Carrillo**

**Doctor en Ingeniería de sistemas y computación**

**Codirector:**

**Cristian Camilo Viáfara Arango**

**Doctor en Ingeniería Mecánica**

**UNIVERSIDAD INDUSTRIAL DE SANTANDER  
FACULTAD DE INGENIERÍAS FÍSICOMECAÑICAS  
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA  
BUCARAMANGA**

**2020**

## **AGRADECIMIENTOS**

El autor expresa su agradecimiento:

A mi padre Antonio Valenzuela Higuera quien a pesar de no poder estar junto a mi en todo momento, siempre ha tenido fe en que puedo lograr grandes cosas. Esforzándose día a día para permitirnos a mi y a mis hermanas alcanzar nuestros sueños.

A mi madre Nancy Rincón Martínez, por ser todo lo que un hijo puede desear y mucho más, por llenar mi vida de amor, por estar siempre ahí cuando más la necesito, preocuparse por mi y guiarme en la toma de decisiones importantes, siendo uno de los pilares más importantes en mi vida.

A mis hermanas Jenny Estefany Valenzuela y Daira Ximena Valenzuela, por cada uno de los momentos especiales en familia que hemos compartido juntos y por todos los que vendrán. Por su apoyo, afecto y cada abrazo de ánimo que me han dado en los momentos de dificultad.

A mi codirector Cristian Camilo Viafara Arango por su paciencia y esfuerzo durante el desarrollo del trabajo, por todo el tiempo y la dedicación que tuvo al compartir conmigo cada uno de los conocimientos, sin los cuales no habría sido posible la culminación de este trabajo.

A mi director Fabio Martínez Carrillo por apoyarme y guiarme desde mis primeros semestres en la universidad. Inculcando en mi el desarrollo de habilidades integrales y profesionales. Por estar siempre dispuesto de solventar cualquier duda a sus estudiantes, y haberme apoyado en este y muchos proyectos más a lo largo de mis

estudios universitarios. Sin su constante guía y consejos no habría sido posible la realización de este trabajo.

Al grupo de investigación *BIVL<sup>2</sup>ab* y a cada uno de sus integrantes, Gustavo, Edgar, Yesid, Isail, Luis, Franklin, Lina, entre muchos otros miembros, por haberme dado su apoyo, conocimientos y experiencias, tanto personales como académicas, permitiéndome crecer como persona y estudiante.

A los excelentes amigos y compañeros con los que compartí esta gran etapa de mi vida, Alejandra Moreno, Hector salazar y sobre todo Victor Mantilla, quien siempre estaba dispuesto a apoyarme ante cualquier adversidad ofreciéndome sus mejores experiencias de vida.

A mi estimada amiga Karen Julie Celis quien a través de su carácter, amistad y cariño, me encamino a buscar un mejor futuro para mi y mis seres queridos.

Muchas gracias a todos.

## CONTENIDO

	pág.
<b>INTRODUCCIÓN</b> . . . . .	<b>12</b>
<b>1. PLANTEAMIENTO Y JUSTIFICACIÓN DEL PROBLEMA</b> . . . . .	<b>19</b>
<b>2. OBJETIVOS</b> . . . . .	<b>20</b>
<b>3. ANÁLISIS DE SUPERFICIES USANDO DESCRIPTORES BASADOS EN GRADIENTES</b> . . . . .	<b>21</b>
3.1. REPRESENTACIÓN HOG . . . . .	21
3.2. REPRESENTACIÓN DAISY . . . . .	22
3.3. MÁQUINA DE SOPORTE VECTORIAL (SVM) . . . . .	24
<b>4. MAPEO DEL DESGASTE USANDO VECTORES EMBEBIDOS DE <i>DEEP LEARNING</i></b> . . . . .	<b>25</b>
4.1. REPRESENTACIÓN DEL DESGASTE USANDO CARACTERÍSTICAS PROFUNDAS . . . . .	26
4.2. APRENDIZAJE Y CLASIFICACIÓN DE MECANISMOS DE DESGASTE Y SEVERIDAD . . . . .	28
4.3. MAPAS DE MECANISMOS DE DESGASTE . . . . .	30
<b>5. MATERIALES</b> . . . . .	<b>32</b>
5.1. DATOS PARA CLASIFICACIÓN GLOBAL . . . . .	32
5.2. DATOS SOBRE MECANISMOS DE DESGASTE . . . . .	34
5.3. DATOS SOBRE SEVERIDAD DE DESGASTE . . . . .	35
<b>6. DISEÑO EXPERIMENTAL</b> . . . . .	<b>40</b>

6.1. VALIDACIÓN DAISY Y HOG . . . . .	40
6.2. CONFIGURACIÓN Y AUMENTO DE LOS DATOS: REVESTIMIENTO DE VERTEDERO . . . . .	41
6.3. MÉTRICAS DE VALIDACIÓN . . . . .	42
6.3.1. Métricas de clasificación . . . . .	43
6.3.2. Métrica de Mapas de desgaste . . . . .	44
<b>7. EVALUACIÓN Y RESULTADOS . . . . .</b>	<b>45</b>
7.1. CLASIFICACIÓN SOBRE IMÁGENES SEM USANDO DESCRIPTORES BASADOS EN GRADIENTE . . . . .	45
7.2. CARACTERIZACIÓN DE MECANISMOS DE DESGASTE EN EL RE- VESTIMIENTO DEL VERTEDERO . . . . .	48
7.2.1. Clasificación supervisada . . . . .	49
7.2.2. Clasificación pseudo-supervisada . . . . .	54
7.3. CARACTERIZACIÓN DE LA SEVERIDAD DEL DESGASTE . . . . .	58
<b>8. DISCUSIÓN . . . . .</b>	<b>61</b>
<b>9. CONCLUSIONES Y PERSPECTIVAS . . . . .</b>	<b>64</b>
<b>BIBLIOGRAFÍA . . . . .</b>	<b>66</b>
<b>APÉNDICES . . . . .</b>	<b>71</b>

## LISTA DE FIGURAS

	<b>pág.</b>
Figura 1. Codificación con diferentes descriptores. . . . .	23
Figura 2. Descripción del enfoque computacional propuesto. . . . .	26
Figura 3. Representación visual del proceso de reconstrucción. . . . .	31
Figura 4. Ejemplos de imágenes pertenecientes a las clases moderado y se- vero. . . . .	33
Figura 5. Imágenes de la superficie desgastada en tres regiones diferentes del revestimiento del vertedero. . . . .	36
Figura 6. Esquema que muestra ejemplos de las imágenes etiquetadas de superficies desgastadas en las regiones de entrada (I) y salida (O). . . . .	37
Figura 7. Imágenes de la superficie desgastada de las muestras de prueba utilizadas para la validación del modelo de clasificación de severidad. . . . .	38
Figura 8. Resultados de la precisión como una función de los parámetros del descriptor de HoG y $k$ particiones. . . . .	46
Figura 9. Rendimiento del modelo en función de los parámetros del descriptor DAISY y las particiones. . . . .	47
Figura 10. Búsqueda iterativa de parámetros para el enfoque de clasificación supervisada de la región de entrada. . . . .	50
Figura 11. Búsqueda iterativa de parámetros para el enfoque de clasificación supervisada para la región de media-salida. . . . .	51
Figura 12. Mapeo de mecanismos de desgaste usado la mejor configuración y el enfoque de clasificación supervisada. . . . .	54

Figura 13. Búsqueda iterativa de parámetros para el enfoque de clasificación pseudo-supervisada. . . . .	55
Figura 14. Mapeo de mecanismos de desgaste usando la mejor configuración aplicada al enfoque de clasificación pseudo-supervisada. . . . .	57
Figura 15. Histograma de clasificación para los niveles de severidad. . . . .	60

## LISTA DE TABLAS

	<b>pág.</b>
Tabla 1. Desviaciones estándar y promedio de las métricas evaluadas para los mecanismos de desgaste. . . . .	52
Tabla 2. Desviaciones estándar y promedio de la métrica <i>DSC</i> para los mecanismos de desgaste del revestimiento usando características profundas y el descriptor HoG. . . . .	53
Tabla 3. Desviaciones estándar y promedio de las métricas evaluadas para los mecanismos de desgaste. . . . .	56
Tabla 4. Promedio y desviaciones estándar de la métrica <i>DSC</i> . . . . .	57
Tabla 5. Desviaciones estándar y promedio de las métricas evaluadas para la severidad del desgaste de los materiales de revestimiento. . . . .	59

## RESUMEN

**TÍTULO:** CUANTIFICACIÓN Y PREDICCIÓN DE MECANISMOS DE DESGASTE EN IMÁGENES DE SUPERFÍCIES DEGRADADAS. \*

**AUTOR:** BRAYAN CAMILO VALENZUELA RINCÓN \*\*

**PALABRAS CLAVE:** CONTROL DE DESGASTE, RECONOCIMIENTO DE PATRONES, ANÁLISIS DE TEXTURA, TÉCNICAS DE PROCESAMIENTO DE IMÁGENES.

**DESCRIPCIÓN:** El desgaste es la principal causa de fallos en muchos sistemas mecánicos debido a las interacciones a las que se expone la superficie del sistema, las cuales se manifiestan como pérdidas de masa. Por lo tanto, la supervisión y análisis del desgaste es fundamental para evitar pérdidas de energía y de tiempo, permitiendo realizar una selección de materiales mas resistentes. Este análisis puede ser llevado usando evaluaciones especiales de laboratorio, que requieren montajes especiales o evaluaciones en condiciones reales, con resultados pocas veces reproducibles. Siendo cualquiera de estos análisis un proceso tedioso y subjetivo para los expertos. Este trabajo introduce un conjunto de herramientas computacionales para la cuantificación y predicción de mecanismos de desgaste en superficies. En primera instancia se propuso un esquema de clasificación automática entre dos regímenes de desgaste, utilizando descriptores de gradiente sobre un conjunto de imágenes de microscopia de barrido electrónico. Los descriptores evaluados resultaron ser suficientes para realizar una apropiada caracterización de las imágenes evaluadas. Luego, en una segunda fase se analizaron mecanismos de desgaste, así como grados de severidad. Para este análisis se propuso una estrategia computacional que codifica parches independientes de las imágenes como características de aprendizaje profundo, capturadas en capas convolucionales de redes pre-entrenadas. Esta codificación es mapeada a una estrategia de aprendizaje de máquina para predecir el mecanismo de desgaste o el grado de severidad asociado a una región en particular. De esta forma fue posible generar mapas de desgaste para ser usados como una herramienta observacional durante el análisis de superficies desgastadas en condiciones de laboratorio o industriales.

---

\* Trabajo de grado

\*\* Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingeniería de Sistemas e Informática. Director: Fabio Martínez, Ph.D. Codirector: Cristian Viáfara, Ph.D.

## ABSTRACT

**TITLE:** QUANTIFICATION AND PREDICTION OF WEAR MECHANISMS IN DEGRADED SURFACE IMAGES. \*

**AUTHOR:** BRAYAN CAMILO VALENZUELA RINCÓN. \*\*

**KEYWORDS:** WEAR CONTROL, PATTERN RECOGNITION, TEXTURE ANALYSIS, IMAGE PROCESSING TECHNIQUES.

**DESCRIPTION:** Wear is the main cause of failure in many mechanical systems due to the interactions to which the system surface is exposed, which manifest themselves as mass losses. Therefore, monitoring and analysis of wear are essential to avoid loss of energy and time, allowing a selection of more resistant materials. This analysis can be carried out using special laboratory evaluations, which require special assemblies or evaluations in real conditions, with results rarely reproducible. Being any of these analyses a tedious and subjective process for experts. This work introduces a set of computational tools for the quantification and prediction of wear mechanisms on surfaces. In the first instance, an automatic classification scheme between two wear regimes was proposed, using gradient descriptors on a set of scanning electron microscopy images. The evaluated descriptors proved to be sufficient to perform an appropriate characterization of the evaluated images. Then, in a second phase, wear mechanisms were analyzed, as well as degrees of severity. For this analysis, a computational strategy was proposed that encodes independent patches of the images as deep features, captured in convolutional layers previously trained networks. This coding is mapped to a machine learning strategy to predict the wear mechanism or degree of severity associated with a particular region. In this way, it was possible to generate wear maps to be used as an observational tool during the analysis of worn surfaces in the laboratory or industrial conditions.

---

\* Degree work

\*\* Faculty of Physics-Mechanics Engineering. School of Systems Engineering and Informatics. Advisor: Fabio Martínez, PhD. Co-advisor: Cristian Viáfara, PhD.

## INTRODUCCIÓN

El desgaste de los componentes de las máquinas es una fuente de diversas pérdidas de material, energía y tiempo que tiene como consecuencia gastos económicos significativos. Una de las soluciones más comunes a este problema es el desarrollo y selección de materiales más resistentes al desgaste con lo que se logre aumentar su vida útil. Las pruebas de laboratorio son económicas, fáciles de ejecutar y sus condiciones de prueba están cuidadosamente controladas. Sin embargo, cuando las pruebas están dirigidas a modelar una aplicación del mundo real, generalmente no se obtiene ninguna correlación, ya que hay inconvenientes en reproducir los mecanismos de desgaste con el mismo nivel de severidad que se encuentra *in situ*. Este hecho podría explicarse por la aceleración de los procesos de cambio de desgaste en el laboratorio <sup>1</sup>. En el caso de los ensayos en campo, ofrecen varias ventajas como la evaluación de las condiciones reales, los bajos costes económicos pero con una pobre reproducibilidad y una alta dispersión de los resultados <sup>2,3,4,5</sup>. En ambos tipos de pruebas, el análisis de las superficies desgastadas constituye una cuestión

---

<sup>1</sup> ONSOYEN, ELDAR. "Accelerated testing of components exposed to wear". En: *Operational Reliability and Systematic Maintenance*. Ed. por HOLMBERG, K. FOLKESON, A. CRC Press, 1991. Cap. 1.3, págs. 51-78.

<sup>2</sup> AVERY, H S. "Materials for the mining industry". En: *Symposium on Materials for the Mining Industry*. Ed. por BARR, R.Q. Vail, Colorado: Climax Molybdenum Company, 1974, págs. 43-78.

<sup>3</sup> ZUM GAHR, K.H. *Microstructure and wear of materials*. Vol. 10. Elsevier, 1987.

<sup>4</sup> HOLMBERG, Kenneth. "Tribological bases for accelerated testing". En: *Operational reliability and systematic maintenance*. Ed. por HOLMBERG, K. FOLKESON, A. CRC Press, 1991. Cap. 1.2, págs. 31-50.

<sup>5</sup> HAWK, Jeffrey A. "Abrasive wear testing". En: *ASM Handbook Vol. 8. Mechanical Testing and Evaluation*. The Materials Information Society, 2000, págs. 694-728.

fundamental que ha sido subvalorada en muchos de los estudios tribológicos.

El análisis de la superficie desgastada se realiza frecuentemente mediante la captura de imágenes en microscopios ópticos y electrónicos que posteriormente son caracterizados por expertos en tribología. No obstante, esa aproximación es manual, subjetiva y propensa a errores en la caracterización del material. Por lo tanto, los sistemas computacionales para cuantificar y representar el mecanismo de desgaste son necesarios para caracterizar los materiales y proporcionar métodos más sensibles para llevar a cabo el análisis en campo. Una representación automática y robusta de los materiales podría derivar en herramientas novedosas para generar una distribución espacial de los mecanismos de desgaste en componentes mecánicos completos, logrando una planificación mucho mejor del mantenimiento de las máquinas.

En la literatura se han propuesto soluciones para este tipo de caracterización utilizando técnicas de reconocimiento de patrones y visión por computador, estas técnicas trabajan en conjunto con algoritmos de aprendizaje automático. En términos generales, esas estrategias utilizan un esquema general que incluye el análisis de imágenes de superficies desgastadas, la codificación de patrones de superficie que relacionan características como el color, la luz, el aspecto geométrico y el perfil de la superficie. Estas características codificadas se asocian a conceptos semánticos de desgaste para entrenar modelos de aprendizaje de máquina que tengan la capacidad de predecir y categorizar nuevas imágenes. Por ejemplo, algunos enfoques se basan en metodologías de reconocimiento de patrones, como el trabajo presentado en <sup>6</sup> propuesto para cuantificar el daño superficial producido como respuesta al contacto rodante-deslizante en pruebas de doble disco. Los autores aplicaron un proceso de análisis de umbral y filtrado de partículas, bajo una hipótesis Bayesiana,

---

<sup>6</sup> BODINI, I., *et al.* "Evaluation of wear in rolling contact tests by means of 2D image analysis". En: *Wear* 400-401. December 2017 (2018), págs. 156-168. DOI: 10.1016/j.wear.2017.12.023.

para seguir la evolución del desgaste de las superficies durante cada etapa de la prueba. De la misma forma, en <sup>7</sup> se propuso una segmentación local de regiones de interés, utilizando un umbral que permite compensar variaciones de iluminación, y junto con operaciones morfológicas se obtienen regiones de interés. Este enfoque se aplicó para cuantificar el nivel de abrasión y micro-picadura que aparece en las imágenes capturadas de las superficies desgastadas. El análisis de imágenes fractales también se ha utilizado para monitorear las superficies desgastadas, introduciendo descriptores visuales que indexan el nivel de las superficies heterogéneas de acuerdo a los procesos caóticos a diferentes escalas de las imágenes <sup>8,9,10</sup>. La evolución del desgaste se ha caracterizado comúnmente a partir de un proceso basado en imágenes que combina fotografías de una superficie obtenidas en diferentes períodos de tiempo y luego detecta los cambios topográficos ocurridos <sup>11, 7</sup>. Así mismo, esta metodología se ha ampliado para predecir los mecanismos de

- 
- <sup>7</sup> SOLEIMANI, Seyfollah, *et al.* "Quantifying abrasion and micro-pits in polymer wear using image processing techniques". En: *Wear* 319.1-2 (2014), págs. 123-137. DOI: 10.1016/j.wear.2014.07.018.
- <sup>8</sup> KIRK, T B, *et al.* "Computer image analysis of wear debris for machine condition monitoring and fault diagnosis". En: *Wear* 181-183 (1995), págs. 717-722. DOI: 10.1016/0043-1648(95)90188-4.
- <sup>9</sup> RAWERS, J y TYLCZAK, J. "Fractal characterization of wear-erosion surfaces". En: *Journal of Materials Engineering and Performance* 8.6 (1999), págs. 669-676. DOI: 10.1361/105994999770346431.
- <sup>10</sup> ABOUEL-KASEM, A, *et al.* "Fractal characterization of slurry eroded surfaces at different impact angles". En: *Journal of Tribology* 131.3 (2009), pág. 31601. DOI: 10.1115/1.3118784.
- <sup>11</sup> SUKUMARAN, J, *et al.* "High-speed imaging for online micrographs of polymer composites in tribological investigation". En: *Wear* 296.1-2 (2012), págs. 702-712. DOI: 10.1016/j.wear.2012.08.016.

desgaste por deslizamiento <sup>12,13</sup>, incluso durante pruebas de contacto <sup>11, 7</sup>. Algunos trabajos también han incluido una correlación cuantitativa entre el comportamiento del desgaste y los parámetros numéricos obtenidos de las imágenes procesadas, lo que podría contribuir a la supervisión de los regímenes de desgaste <sup>14, 11, 13,15</sup>. Estos enfoques, sin embargo, presentan notables limitaciones para hacer frente a las múltiples variaciones de la imagen y el ruido asociado durante la captura. Otros métodos han dedicado esfuerzos a integrar los descriptores visuales con el enfoque de aprendizaje de máquina para caracterizar los mecanismos de desgaste en materiales específicos y desde diferentes niveles de observación. El trabajo propuesto por Stachowiak <sup>16</sup> *et al.* sugiere un enfoque de clasificación automática del desgaste, implementando descriptores de textura *wavelet* y un modelo de máquina de soporte vectorial lineal (*Support Vector Machine - SVM*). Este enfoque se evaluó en tres tipos diferentes de desgaste: fatiga, abrasivo y adhesivo, utilizando imágenes de microscopia de barrido electrónico (*Scanning electron microscopy - SEM*).

- 
- <sup>12</sup> TASAN, Y C; DE ROOIJ, M B y SCHIPPER, D J. "Measurement of wear on asperity level using image-processing techniques". En: *Wear* 258.1-4 (2005), págs. 83-91. DOI: 10.1016/j.wear.2004.05.018.
- <sup>13</sup> MEYLAN, B, *et al.* "A simple, fast and low-cost method for in situ monitoring of topographical changes and wear rate of a complex tribo-system under mixed lubrication". En: *Wear* 364-365 (2016), págs. 22-30. DOI: 10.1016/j.wear.2016.06.006.
- <sup>14</sup> ZHANG, J. "Detection and monitoring of wear using imaging methods". Tesis doct. University of Twente, 2006.
- <sup>15</sup> BODINI, I, *et al.* "Evaluation of wear in rolling contact tests by means of 2D image analysis". En: *Wear* 400-401 (2018), págs. 156-168. DOI: 10.1016/j.wear.2017.12.023.
- <sup>16</sup> PODSIADLO, P. y STACHOWIAK, G. W. "Characterization of surface topography of wear particles by SEM stereoscopy". En: *Wear* 206.1-2 (1997), págs. 39-52. DOI: 10.1016/S0043-1648(96)07324-3.

Además, en <sup>17,18</sup> las imágenes de la superficie desgastada de ejemplares de hierro fundido se caracterizaron a partir de descriptores basados en gradientes, como el histograma de gradiente orientado (*Histogram of Oriented Gradients - HoG*) y el descriptor DAISY. Luego, se implementó una clasificación automática a partir de los modelos de bosque aleatorio (*Random Forest - RF*) y *SVM*.

Los enfoques más recientes han utilizado un sofisticado método de aprendizaje profundo de principio a fin para modelar y clasificar los mecanismos de desgaste. Por ejemplo, se propuso una arquitectura convolucional para clasificar partículas de desgaste, según diferentes modelos y mecanismos de formación <sup>19</sup>. También, en Chang *et al.*<sup>20</sup> aplican arquitecturas convolucionales para clasificar los mecanismos de desgaste y la severidad. A partir de este enfoque también fue posible analizar la distribución espacial del desgaste a lo largo de la imagen de entrada. Estos métodos han mostrado la necesidad de integrar descriptores más robustos para representar adecuadamente los mecanismos de desgaste. A pesar de los notables resultados, estos trabajos dependen fuertemente del proceso de aprendizaje o entrenamiento para determinar el modo, mecanismo o severidad del desgaste. Además, ese enfoque podría estar sujeto a problemas de sobre ajuste que podría limitar su reproducción

---

<sup>17</sup> GONZALEZ-ARIAS, C., *et al.* "Automatic classification of severe and mild wear in worn surface images using histograms of oriented gradients as descriptor". En: *Wear* 426-427 (2019), págs. 1702-1711. DOI: 10.1016/j.wear.2018.11.028.

<sup>18</sup> VALENZUELA, Brayan; VIÁFARA, Cristian y MARTÍNEZ, Fabio. "Analysis of worn surface images using gradient-based descriptors". En: *2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA)*. IEEE. 2019, págs. 1-5. DOI: 10.1109/STSIVA.2019.8730247.

<sup>19</sup> WANG, S., *et al.* "Integrated model of BP neural network and CNN algorithm for automatic wear debris classification". En: *Wear* 426-427. September 2018 (2019), págs. 1761-1770. DOI: 10.1016/j.wear.2018.12.087.

<sup>20</sup> CHANG, Haichuan; BORGHESANI, Pietro y PENG, Zhongxiao. "Automated assessment of gear wear mechanism and severity using mould images and convolutional neural networks". En: *Tribology International* 147 (2020), pág. 106280. DOI: 10.1016/j.triboint.2020.106280.

en otros conjuntos de datos de mecanismos de desgaste.

En este trabajo se exploran y proponen dos estrategias computacionales para la cuantificación y predicción de mecanismos de desgaste. En una primera aproximación, se exploran descriptores visuales basados en gradientes para caracterizar y predecir los regímenes de desgaste moderado o severo en un conjunto de imágenes de microscopía de barrido electrónico (*SEM*) de las superficies de desgaste por abrasión. En una segunda aproximación se propone un enfoque, basado en características de aprendizaje profundo para representar superficies desgastadas en cuanto a la clasificación de mecanismos y la predicción del nivel de severidad en una superficie. En cuanto a la predicción del mecanismo de desgaste, también fue posible construir un mapa con la distribución espacial del mismo a lo largo de toda la imagen evaluada, soportando el análisis realizado por expertos. Tanto para la clasificación de mecanismos de desgaste como para la estimación de severidad, cada una de las imágenes se divide en parches que luego se describen con características profundas embebidas, recuperadas de redes neuronales convolucionales pre-entrenadas. Una de las principales ventajas de esta representación en lo que respecta al aprendizaje, es la capacidad de caracterizar el mecanismo de desgaste con pocas muestras para el entrenamiento y la representación de alta variabilidad. Estas características se codifican con un análisis de componentes principales y luego se mapean a un clasificador *RF* para realizar una predicción de desgaste/severidad de cada parche. Con respecto a la cuantificación regional de los mecanismos de desgaste, una vez entrenado el clasificador, fue posible obtener un mapa de desgaste al realizar localmente un ventaneo para toda la imagen en evaluación. Esta estrategia computacional fue evaluada con dos conjuntos de datos diferentes de imágenes de superficie desgastadas que permiten valorar las dos diferentes tareas propuestas: clasificación de mecanismos de desgaste y predicción de niveles de severidad. Los resultados obtenidos demostraron una capacidad robusta del enfoque

propuesto para caracterizar las superficies desgastadas en el conjunto de imágenes correspondientes.

## 1. PLANTEAMIENTO Y JUSTIFICACIÓN DEL PROBLEMA

En diferentes procesos industriales, como por ejemplo, los procesos de extracción de minerales pesados es bastante común que los componentes de las herramientas, como las placas de revestimiento, sufran desgaste debido a eventos de fricción e impacto en la superficie. Este desgaste conlleva grandes pérdidas económicas relacionadas con procesos de mantenimiento y reparación.

El análisis convencional del desgaste es realizado con base en la replicación de las condiciones del funcionamiento de las diversas herramientas usadas en el campo de trabajo con el fin de analizar el desgaste en el laboratorio. Sin embargo, este desgaste puede carecer de correlación con el que se da en ambientes industriales. Adicionalmente, el análisis de las superficies desgastadas realizado por los expertos en tribología pueden ser altamente subjetivos utilizando microscopios estereoscópicos y electrónicos de barrido. Por otra parte, el análisis directo de la placa emplea técnicas como: mediciones de pérdida de volumen, diferencia topográfica, entre otras. Estas técnicas, no obstante, requieren el desmonte de las piezas de estudio. Además, dichos análisis, tanto en laboratorios como industriales, dependen de la valoración y etiquetado subjetivo llevado a cabo por parte de un experto. Para abordar esta problemática, se han propuesto diversas metodologías que dan uso a técnicas visuales representando los tipos de desgaste como modelos texturales no uniformes. Sin embargo, los descriptores clásicos propuestos para la caracterización de estas texturas no recopilan las múltiples características de cada desgaste, induciendo muchas veces a marcaciones erróneas en las regiones de la placa.

## **2. OBJETIVOS**

### **Objetivo general**

- Predecir mecanismos locales de desgaste en imágenes de superficies degradadas en condiciones de laboratorio e industriales.

### **Objetivos específicos**

- Procesar el conjunto de imágenes de desgaste junto con sus correspondientes marcaciones.
- Desarrollar una estrategia de clasificación que permita reconocer mecanismos y regímenes de desgaste a nivel regional.
- Reconstruir mapas locales de desgaste a partir de las predicciones generadas por el modelo de clasificación.
- Validar el modelo de clasificación y reconstrucción utilizando medidas como la precisión y el factor de superposición entre los regímenes reconstruidos.

### 3. ANÁLISIS DE SUPERFICIES USANDO DESCRIPTORES BASADOS EN GRADIENTES

En un análisis inicial de superficies llevado a cabo en este trabajo, se desarrolló una estrategia computacional para caracterizar y predecir entre dos tipos de regímenes de desgaste, observados desde imágenes *SEM* de superficies desgastadas por abrasión. Para ello, se exploraron dos descriptores diferentes basados en gradientes: el *HoG* y el descriptor *DAISY*. Se entrenaron algoritmos de aprendizaje de máquina para resolver la tarea de clasificación de regímenes de desgaste de forma automática. En este capítulo se expone el método propuesto en esta fase inicial de análisis. *El contenido completo de este capítulo ha sido publicado en 2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA) (ver artículo aquí<sup>21</sup>).*

#### 3.1. REPRESENTACIÓN HOG

El descriptor *HoG* es una representación basada en gradientes, muy bien conocida, que resulta útil para codificar superficies de desgaste representadas con gradientes predominantes en imágenes. Este descriptor consigue una estimación densa y redundante de histogramas de gradientes, los cuales son computados siguiendo una ventana deslizante. Para eliminar artefactos o valores atípicos de gradiente, los histogramas están normalizados con respecto a su vecindad. El histograma de gradientes da una idea de las orientaciones principales reportadas dentro de una región específica, mientras que el cálculo denso a lo largo de la imagen resulta ser robusto

---

<sup>21</sup> VALENZUELA, Brayan; VIÁFARA, Cristian y MARTÍNEZ, Fabio. "Analysis of worn surface images using gradient-based descriptors". En: *2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA)*. IEEE. 2019, págs. 1-5.

con respecto a la variabilidad de representación de características superficiales de desgaste<sup>22</sup>.

El cálculo denso de *HoG* empieza seccionando una imagen en un conjunto de parches regulares  $c_i$ . Los gradientes  $\nabla c_i$  dentro de cada parche son resumidos utilizando un histograma de gradientes  $H_i$ . En este caso, los bins  $\omega$  son definidos por intervalos de orientaciones, los cuales son ponderados con respecto a la norma de cada vector gradiente como:  $H_i(\omega) = \sum_{\{\phi(\nabla c)=\omega\}} \|\nabla c\|$ . Cada uno de los bins  $\omega$  están normalizados con respecto a la suma total de la norma de los gradientes. Adicionalmente, el descriptor *HoG* tiene un bloque de normalización con respecto al número total de bins de todos los histogramas en una región específica, expresado como  $b_n = \frac{b_n}{\sqrt{\|b_n\| + \varepsilon}}$  donde  $\varepsilon$  es una cantidad que previene la división por cero. Se espera que las superficies con desgaste moderado sean representadas con un histograma uniforme manteniendo una probabilidad equitativa para todas las orientaciones de los gradientes. Por otra parte, en las imágenes de superficies de desgaste severo, algunos parches son representados por histogramas asimétricos describiendo falta de uniformidad de la superficie.

### 3.2. REPRESENTACIÓN DAISY

En este trabajo se evaluó un descriptor que proporciona una representación adicional basada en gradientes. Este descriptor se denomina DAISY y permite realizar, al igual que el descriptor HoG, la caracterización de superficies desgastadas. Este descriptor de gradientes multi-escala fue desarrollado originalmente para una comparación densa y el emparejamiento de imágenes que han sufrido alguna transformación geométrica. Hoy en día, este descriptor es ampliamente utilizado en tareas de re-


---

<sup>22</sup> KITTIPANYA-NGAM, Panachit y LUNG, Eng How. "HOG-based descriptors on rotation invariant human detection". En: *Asian Conference on Computer Vision*. Springer. 2010, págs. 143-152.

conocimiento de objetos debido a la robustez demostrada, las propiedades de invarianza con respecto a la escala y rotación, así como por su eficiencia computacional. En este descriptor, una imagen  $I$  es convolucionada una determinada cantidad de veces con un filtro gaussiano  $G_{\Sigma}$ , capturando diferentes mapas de orientación de gradientes  $o(x, y)$ . Este proceso puede ser expresado como:  $G_{\Sigma}^{\nabla} = G_{\Sigma} * \frac{\partial I}{\partial o(x,y)}$ . Un total de ocho mapas de orientación convolucionados fueron obtenidos, los cuales operan a diferentes escalas gaussianas.

En cada posición de píxel es fijado un conjunto de círculos concéntricos como se ilustra en la figura-1 para calcular diferentes histogramas de orientación, que representan cada una de las subregiones. Esta estructura particular de círculos concéntricos permite la invarianza a la rotación, dando como resultado, por ejemplo, caracterizar los mismos patrones de desgaste severos que son rotados en diferentes muestras de las imágenes. A su vez, la naturaleza multi-escala permite una mejor diferenciación a lo largo del régimen moderado y severo, estando presentes los patrones de los gradientes en todas las escalas para el régimen severo. Una ventaja adicional de la configuración circular es el diseño de filtros simétricos que pueden ser calculados más rápido en comparación con otros descriptores.

**Figura 1.** Ejemplo de las estructuras de codificación de ambos descriptores de gradientes aquí evaluados. En la imagen de la izquierda se ilustra el funcionamiento típico del descriptor HoG, que codificó regionalmente los histogramas de gradientes orientados. En la imagen del medio está la imagen original que corresponde a una clase severa. En la imagen de la derecha se muestra la geometría del núcleo utilizada para calcular los gradientes en el descriptor DAISY.



### 3.3. MÁQUINA DE SOPORTE VECTORIAL (SVM)

El reconocimiento de una superficie de desgaste puede ser llevada a cabo por una máquina de soporte vectorial *SVM*, debido a su robustez, generalización, precisión y bajo costo computacional <sup>23</sup>. El enfoque presente fue implementado utilizando una función de base radial (en inglés, *Radial Basis Function - RBF*) expresada como  $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$ , con  $(x_i, x_j)$  siendo la diferencia entre las muestras de regímenes leves y severos. Estas muestras son caracterizadas por un vector  $n$ -dimensional  $x \in R^n$  codificado con los descriptores de gradiente *HoG* o *DAISY*. A partir de estas características, dentro del descriptor son construidos hiperplanos óptimos que se separan por una formulación clásica de margen máximo.

---

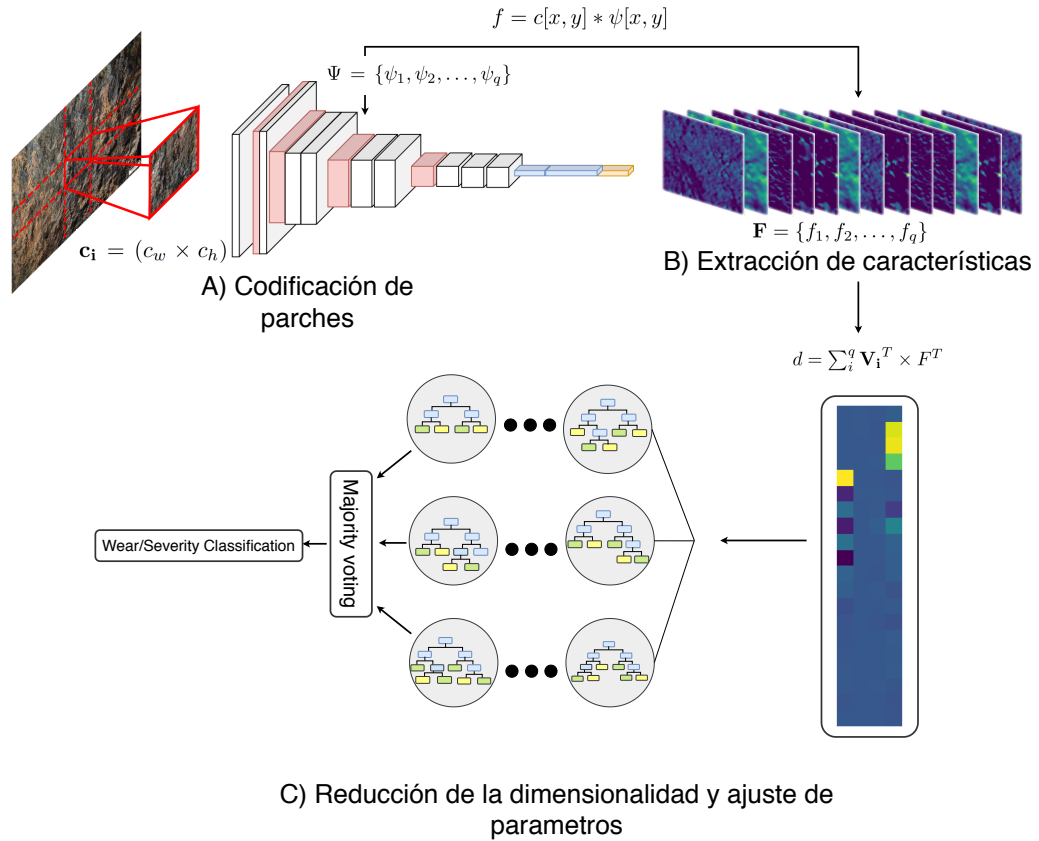
<sup>23</sup> CHANG, Chih Chung y LIN, Chih Jen. "LIBSVM: a library for support vector machines". En: *ACM transactions on intelligent systems and technology (TIST)* 2.3 (2011), pág. 27.

#### 4. MAPEO DEL DESGASTE USANDO VECTORES EMBEBIDOS DE *DEEP LEARNING*

Este trabajo introduce un enfoque automático con la capacidad de clasificar tipos de desgaste, predecir la severidad del desgaste de un mecanismo y generar mapas con la distribución espacial del mismo a partir de imágenes de superficies desgastadas. Una implementación de este enfoque fue realizada con imágenes de placas de revestimiento de vertederos, las cuales estuvieron bajo condiciones de campo. En la primera parte de este enfoque, se recortan imágenes de superficies de desgaste en parches  $c_i = (c_w \times c_h)$  que permiten una caracterización regional de mecanismos de desgaste. Luego, cada parche es representado de manera profunda con un conjunto de activaciones, las cuales son extraídas de redes neuronales convolucionales pre-entrenadas. Estas características profundas (activaciones) descomponen la información de los parches de mecanismos de desgaste en primitivas fundamentales de imágenes (ver la Figura 2(b)). En la etapa de entrenamiento, el conjunto de activaciones asociadas a cada parche junto con sus etiquetas correspondientes, son usadas para entrenar un clasificador de *RF* para realizar reconocimiento automático de mecanismos/severidad de desgaste. En la etapa de validación, cada parche local representado por el descriptor de características profundas, es proyectado en un *Random Forest* para obtener predicciones de desgaste. Adicionalmente, dentro de un esquema de ventana deslizante, fue posible reconstruir la imagen de la placa. En este caso, las regiones en movimiento que representan cada píxel en la imagen, son mapeadas satisfactoriamente para obtener un mapa completo de los mecanismos de desgaste.

*El contenido completo de este capítulo hace parte del artículo: Wear mapping by propagating regional labels coded as embedding deep learning vectors (estado: en revisión).*

**Figura 2.** Descripción del enfoque computacional propuesto.



#### 4.1. REPRESENTACIÓN DEL DESGASTE USANDO CARACTERÍSTICAS PROFUNDAS

Los mecanismos de desgaste son caracterizados acorde a patrones como gradientes, texturas y apariencia. Las metodologías automáticas en visión por computador han aprovechado algunas de estas características para describir las firmas visuales asociadas a estos mecanismos. Hoy en día, las representaciones de imágenes exitosas se obtienen desde redes neuronales profundas (en inglés, *Deep neuronal networks*) que aprenden de forma jerárquica patrones primitivos y permiten identificar diferentes instancias de alto nivel, que potencialmente podrían utilizarse en la clasi-

ficación de los mecanismos de desgaste y en la estimación de niveles de severidad. No obstante, estas arquitecturas requieren grandes conjuntos de datos etiquetados para ajustarse a las representaciones visuales y hacer frente a una gran variabilidad visual, lo que en tribología es una tarea tediosa que requiere mucho tiempo.

Para tratar este problema, en este trabajo, se capturaron características visuales de redes pre-entrenadas, tomando características profundas de los primeros niveles de representación (primeras capas). Estos rasgos profundos evitan un aprendizaje exhaustivo de mecanismos específicos de desgaste, y capturan eficazmente los patrones de este tipo de imágenes. En este caso, la representación de la imagen obtenida por aprendizaje profundo está codificada, en cada capa, como un conjunto de  $q$  filtros  $\Psi = \psi_1, \psi_2, \dots, \psi_q$  pertenecientes a una red convolucional pre-entrenada. El conjunto de imágenes de superficie desgastada tomadas de los revestimientos de vertederos se dividieron en regiones relativamente pequeñas, que delimitaron mecanismos de desgaste independientes. Cada región es entonces un pequeño parche de imagen  $c_i$ , con dimensiones  $(c_w \times c_h)$  los cuales son operados con cada uno de los  $q$  filtros  $\psi_j$ , siguiendo la operación  $f = c[x, y] * \psi[x, y]$ , descrita como:

$$f[x, y] = \sum_{j=1}^{2n+1} \sum_{i=1}^{2n+1} C[x - n + i - 1, y - n + j - 1] \psi[i, j] \quad (1)$$

Las características profundas obtenidas, son un conjunto de parches de activación  $\mathbf{F} = \{f_1, f_2, \dots, f_q\}$ , donde cada  $f_i$  tiene las mismas dimensiones que el parche extraído de la imagen, destacando los patrones de desgaste relevantes y preservando la estructura espacial de la imagen, *i.e.*,  $(c_w \times c_h)$ . Así estas características son expresadas como la respuesta del banco de filtros  $q$  que separan la información en una banda de frecuencia especial, pero en este caso con la ventaja de ser el resultado de una descomposición progresiva, jerárquica y no lineal. Así, en cada rasgo obtenido por aprendizaje profundo se espera que se recuperen las propiedades visuales

representativas de los mecanismos de desgaste, tales como la textura y el color, los cuales podrían modelar con eficacia el problema de clasificación.

Las características profundas  $F$  tienen una representación *sparse*, con pocas activaciones no nulas que son relevantes. Debido a esto, se calculó un descriptor a partir de estas características para recuperar los componentes principales expresados como combinaciones de rasgos lineales que maximizan la varianza en cada dimensión. Para ello, se calcula una matriz de covarianza entre las características profundas, definida como:  $\Sigma_F = E[FF^T] - \mu_F\mu_F^T$ , donde  $E$  es el valor esperado y  $\mu_F$  el vector de característica promedio.

Este descriptor de covarianza  $\Sigma_F \in \mathbb{R}^{c_w c_h \times c_w c_h}$  es una matriz semidefinida positiva y simétrica que puede ser expresada en sus respectivos *auto vectores*  $V$  y *auto valores*  $\lambda$ , como  $\Sigma_F = V\lambda V^T$ , donde  $\lambda = \{\lambda_1, \lambda_2, \dots, \lambda_q\}$  podría utilizarse para proyectar información sobre el eje que maximice la varianza entre las características profundas. De esta forma, los *auto valores* más importantes son seleccionados para proyectar información sobre una dimensión inferior con respecto a los componentes principales, como  $d = \sum_i^q V_i^T \times F^T$ . Así  $d$  es el descriptor final de cada parche con el que se caracteriza completamente los mecanismos de desgaste. Esta representación resulta ser descriptiva incluso para caracterizar la severidad de los mecanismos de desgaste, siendo un punto relevante en el análisis progresivo de fenómenos particulares.

## **4.2. APRENDIZAJE Y CLASIFICACIÓN DE MECANISMOS DE DESGASTE Y SEVERIDAD**

Para lograr una clasificación automática de mecanismos de desgaste y severidad, en este trabajo se ha implementado un algoritmo de aprendizaje supervisado que permite aprender de un conjunto de parches, definidos por el respectivo conjunto de descriptores visuales. Luego, se utiliza un conjunto de  $m$  descriptores de parches

de entrenamiento  $d_1, d_2, \dots, d_m$  para construir un modelo de clasificación que permite establecer límites entre las categorías de mecanismos de desgaste o niveles de severidad con un error marginal. Cada tarea de clasificación para una muestra particular puede ser modelada como la probabilidad de pertenecer a una clase  $y_i$  dado un descriptor obtenido por aprendizaje profundo  $d_i$  particular. En este trabajo se consideró una partición del espacio de características discretas entre las características que representan el mecanismo de desgaste, y porque debido a su naturaleza (vector no correlacionado, resultado del análisis de componentes principales) puede tener un mejor rendimiento con representaciones basadas en árboles de decisión. En ese orden de ideas, el algoritmo de clasificación de *RF*<sup>24</sup> consiste en un enfoque de ensamble que integra múltiples Árboles de Decisión (*Decision Trees - DT*), fue implementado para clasificar los mecanismos de desgaste y niveles de severidad. Así, cada *Decision Tree* denotado por  $\theta_b = (j, \tau_m)$  representa ramas aprendidas con umbrales de partición  $\tau_m$  a lo largo de las características, siendo estas cada uno de los nodos de decisión  $j$ . Una de las principales ventajas de este clasificador es la descripción de los resultados y la posibilidad de comprender visualmente la etiqueta predicha a través de las ramas de las características. Los árboles que representan de forma independiente la hipótesis de la partición de las características se construyeron a partir de un análisis óptimo y discriminante usando la estrategia *CART - Classification and Regression Trees*. A continuación, el *Random Forest* (que, de hecho, es un conjunto de *Decision Trees*) utiliza una estrategia de agregación de *Bootstrap* para integrar diferentes clasificadores mediante la selección aleatoria de las características que construyen cada *DT* en el *RF*. De este proceso se obtiene un total de  $B$  árboles que predicen de forma independiente el mecanismo de desgaste más probable de las características aprendidas, preservando la eficiencia compu-

---

<sup>24</sup> TIBSHIRANI, Robert y HASTIE, Trevor. "Margin Trees for High-dimensional Classification". En: *Journal of Machine Learning Research* 8 (2007), págs. 637-652.

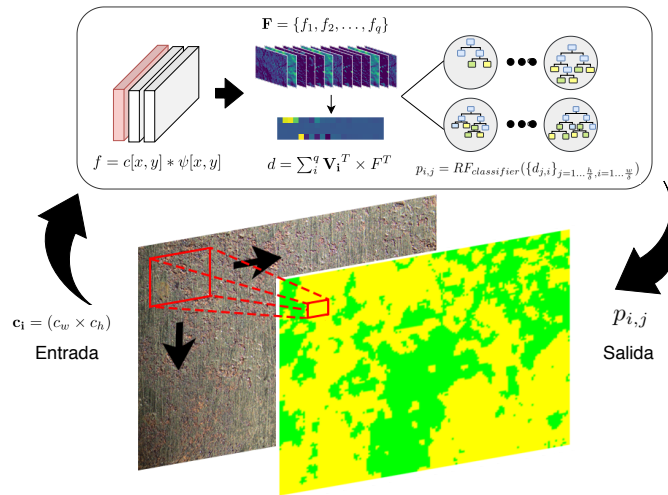
tacional. Finalmente, la predicción más probable se selecciona de acuerdo a una votación por mayoría, realizada a partir de predicciones completas de los  $DT$ , como  $\hat{y} = \arg \max\{\theta_1, \dots, \theta_B\}$ . En este enfoque, la clasificación de las características permite establecer dos tareas diferentes sobre el conjunto de datos correspondiente: la clasificación de mecanismos de desgaste (un total de cinco clases) y la severidad del mismo (cinco niveles). Mientras que los clasificadores de  $DT$  podrían tener un sesgo bajo y una varianza muy alta, el algoritmo  $RF$  reduce la variabilidad de la predicción utilizando la expectativa sobre un conjunto de algoritmos de  $DT$  independientes, entrenados sobre diferentes partes del espacio de características profundas.

### 4.3. MAPAS DE MECANISMOS DE DESGASTE

Una de las principales tareas del análisis tribológico es estudiar los patrones de desgaste espacial a lo largo de las zonas de trabajo en los revestimientos, lo que permite comprender la severidad y pronosticar el posible mecanismo de desgaste responsable de la falla. Una imagen de mapa de desgaste se obtiene propagando la clasificación del mecanismo, a partir de un proceso de escaneo realizado a lo largo de la imagen. Para ello, se implementó un proceso de ventana deslizante para obtener una clasificación del mecanismo de desgaste asociado a cada píxel. Luego, en cada iteración se toma una región vecina, de dimensiones  $(c_w \times c_h)$ , centrada en el píxel  $p_{i,j}$  para ser clasificada. Cada región está representada por un conjunto de filtros convolucionales profundos, los cuales son codificados a partir de sus respectivos componentes principales. Luego, este descriptor es mapeado a un  $RF$ , previamente entrenado, para así obtener una etiqueta de desgaste para cada píxel, descrita como  $p_{i,j} = RF_{classifier}(\{d_{j,i}\}_{j=1 \dots \frac{h}{8}, i=1 \dots \frac{w}{8}})$ . Este proceso se realiza a lo largo de toda la imagen analizada para así generar una imagen de mapa de desgaste. En muchas de las imágenes estudiadas, el mecanismo de desgaste representa regiones grandes y gruesas, de tal forma, es posible obtener mapas de desgaste cada

$\delta$  píxeles. Estos mapas son de baja resolución permitiendo obtener el resultado en una menor cantidad de tiempo, lo que puede ser importante para apoyar las decisiones *in situ*, sobre los procesos industriales. Esta etapa de reconstrucción se ejemplifica en la figura-3.

**Figura 3.** Representación visual del proceso de reconstrucción.



## 5. MATERIALES

### 5.1. DATOS PARA CLASIFICACIÓN GLOBAL

Para el análisis de desgaste en laboratorio se procesaron un conjunto de imágenes de superficies desgastadas por abrasión, donde diferentes hierros fundidos fueron puestos en contacto (deslizamiento) contra diferentes tipos de abrasivos. Los detalles adicionales de las condiciones del test, pueden ser encontrados en <sup>25,26</sup>. Las imágenes *SEM* permiten identificar patrones de superficie relacionados con el tipo de efectos mecánicos o químicos generados durante el proceso de desgaste. Por lo tanto, el análisis de superficies de desgaste es usado para establecer correlaciones entre las características de la superficie con el comportamiento del desgaste. El comportamiento de cada combinación de hierro fundido con una abrasión específica, resultó en una tasa de desgaste particular. Las tasas de desgaste altas y bajas están asociadas con el régimen de desgaste severo y moderado, respectivamente. Para toda la validación, fue utilizado un conjunto de datos con un total de 50 muestras, distribuidas en 29 muestras etiquetadas como clase “severa”, siendo las 21 imágenes restantes etiquetadas con la clase “moderada”.

Las imágenes *SEM* con dimensiones de  $256 \times 256$  fueron capturadas para caracterizar las superficies en 3D. Estas superficies de desgaste con régimen moderado tuvieron una apariencia suave y una baja cantidad de ranurados, mientras que las


---

<sup>25</sup> CORONADO, J J; RODRÍGUEZ, S A y SINATORA, A. “Effect of particle hardness on mild-severe wear transition of hard second phase materials”. En: *Wear* 301.1-2 (2013), págs. 82-88. DOI: 10.1016/j.wear.2012.12.016.

<sup>26</sup> GONZÁLEZ-ARIAS, C, *et al.* “Automatic classification of severe and mild wear in worn surface images using histograms of oriented gradients as descriptor”. En: *Wear* (Article in press, 2018). DOI: 10.1016/j.wear.2008.11.019.

superficies de desgaste con régimen severo tenían una superficie más rugosa con huellas de deformación plástica y ranuras más profundas <sup>25</sup>. De esta manera, las características de superficie, capturadas en las imágenes, podrían ser modeladas como patrones de gradientes no uniformes. Por otra parte, el desgaste moderado produce un gradiente más suave y uniforme. No obstante, una predicción computacional automática de la severidad del desgaste, es una tarea desafiante debido a la gran variedad de patrones de gradientes a lo largo de la superficie. En este trabajo, una cuantificación de gradientes locales es realizada utilizando dos codificaciones de gradientes conocidas: Los descriptores HoG <sup>27</sup> y DAISY <sup>28</sup>. En la figura 4 se muestran ejemplos de imágenes pertenecientes a los regímenes ya mencionados.

**Figura 4.** Ejemplos de imágenes pertenecientes a las clases “moderado” y “severo”.



- 
- <sup>27</sup> KITTIPANYA-NGAM, Panachit y LUNG, Eng How. “HOG-Based Descriptors on Rotation Invariant Human Detection”. En: *Computer Vision – ACCV 2010 Workshops. ACCV 2010. Lecture Notes in Computer Science*. Ed. por KOCH, Reinhard y HUANG, Fay. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010, págs. 143-152. DOI: 10.1007/978-3-642-22822-3\_15.
- <sup>28</sup> TOLA, Engin; LEPETIT, Vincent y FUA, Pascal. “Daisy: An efficient dense descriptor applied to wide-baseline stereo”. En: *IEEE transactions on pattern analysis and machine intelligence* 32.5 (2010), págs. 815-830.

## 5.2. DATOS SOBRE MECANISMOS DE DESGASTE

Un grupo de imágenes fueron capturadas de una superficie desgastada del revestimiento de un vertedero en una planta de extracción de mineral de hierro. El revestimiento estaba situado en una región del vertedero donde se producía el deslizamiento del mineral de hierro, en un ambiente con humedad natural. Una descripción más detallada del revestimiento se da en <sup>29</sup>. Las imágenes de bajo aumento de la superficie desgastada se capturaron usando microscopía estereoscópica. La superficie de trabajo del revestimiento era de aproximadamente  $190 \times 390mm^2$ . Luego se utilizó un método para tener una caracterización representativa de los mecanismos de desgaste sobre la superficie de trabajo <sup>29</sup>. El método para el proceso de captura de imágenes consistió en caracterizar tres regiones principales del revestimiento: las regiones de entrada, media y salida. Cada región de análisis cubría un área total de catorce pulgadas cuadradas. De esta manera, el conjunto de datos consta de 168 imágenes, de las cuales 7 se etiquetaron completamente a mano y se utilizaron para evaluar el enfoque propuesto. Tres de estas imágenes pertenecientes a la región de entrada y cuatro a la región de salida y media. Se realizó un proceso de etiquetado para identificar los mecanismos de desgaste presentes en las imágenes de la superficie desgastada, que permite entrenar y evaluar el enfoque propuesto. En la Figura-5 se muestra un resumen de las imágenes estereoscópicas de las tres regiones del revestimiento. Se identificaron cinco áreas específicas como representativas de un mecanismo de desgaste operativo. Un análisis detallado de los mecanismos de desgaste se puede encontrar en <sup>29</sup>. Como resultado, el proceso de etiquetado permitió inferir que existen cinco mecanismos de desgaste distintos,

---

<sup>29</sup> VIÁFARA, Cristian Camilo, *et al.* "Wear modes and mechanisms in chute linings: An advance in their understanding from the characterization of worn linings supported by computer vision tools". En: *in preparation* (2020).


como se puede ver en la Figura-6. Esta figura muestra ejemplos de las imágenes etiquetadas para cada región del revestimiento.

### **5.3. DATOS SOBRE SEVERIDAD DE DESGASTE**

Se utilizó un conjunto adicional de datos de imágenes para validar la estrategia computacional desarrollada en cuanto a la capacidad de reconocer diferentes grados de severidad en el desgaste. En este caso, se tomaron muestras de las imágenes de las superficies desgastadas, en una prueba de campo, realizada en un vertedero (canaleta) para el transporte del mineral de hierro. Se utilizaron muestras de cinco hierros fundidos blancos diferentes, que se denominaron ( $A, C, C_m, E_m, R$ ), cada una de las muestras mencionadas tiene un porcentaje de cromo inferior al 12%, característica que permite reducir su coste manteniendo una considerable resistencia al desgaste. Para realizar el análisis de severidad cada material tenía al menos cuatro muestras en las que se identificaba el nivel de severidad que poseía. De esta manera, este conjunto de datos consiste en 20 imágenes de cinco grados de severidad diferentes.

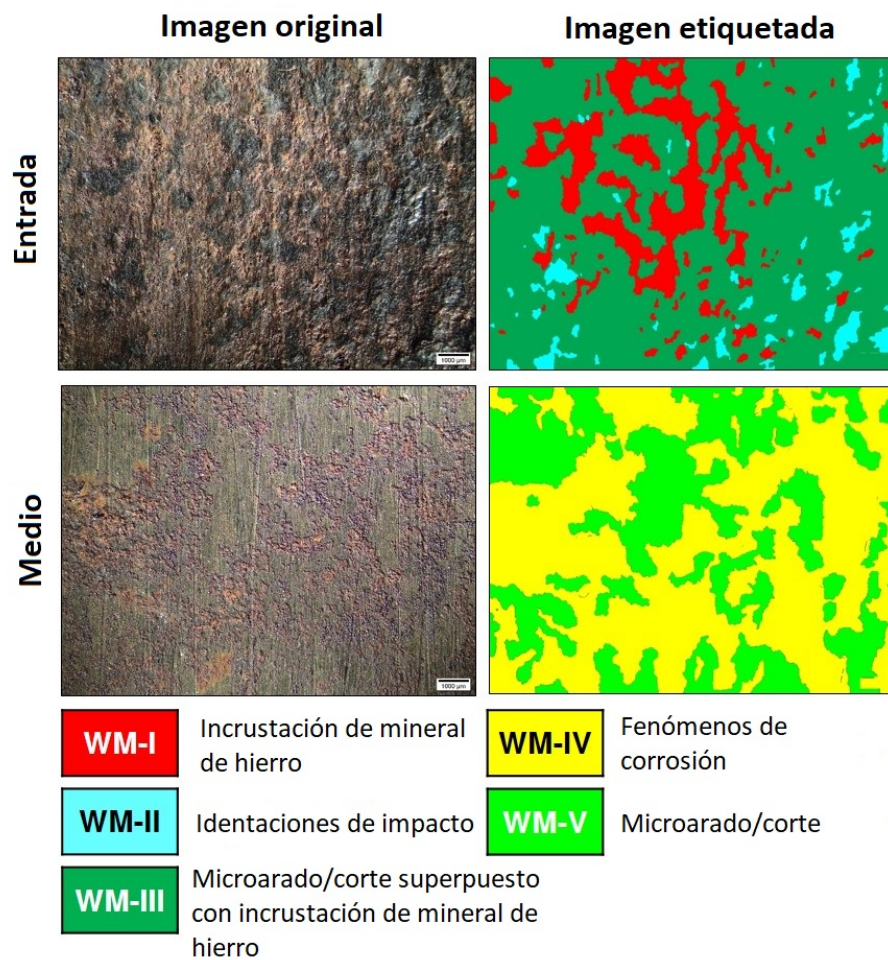
Un proceso de etiquetado fue llevado a cabo sobre el conjunto de datos para realizar el entrenamiento del modelo de clasificación. Para realizar esta tarea de etiquetado se realizó un análisis visual detallado de las imágenes de las superficies desgastadas para determinar diferentes niveles de apariencia de desgaste según las características de la superficie. Estos pueden llegar a ser niveles asociados a la severidad del mismo. En la Figura-7 se muestran las imágenes seleccionadas en las que se marcó un cuadrante como representativo de cada nivel de severidad del desgaste, con unas dimensiones medias de  $(800 \times 900)$ , de modo que sólo se tienen en cuenta las regiones marcadas para la etapa de entrenamiento. Se identificaron cinco niveles de severidad del desgaste, en los que se observaron diferentes combinaciones de ausencia y presencia de micro cortes y marcas de corrosión, denominadas: des-

**Figura 5.** Imágenes de la superficie desgastada en tres regiones diferentes del revestimiento del vertedero.




gaste leve, desgaste abrasivo leve, desgaste corrosivo, desgaste abrasivo-corrosivo, desgaste severo.

**Figura 6.** Esquema que muestra ejemplos de las imágenes etiquetadas de superficies desgastadas en las regiones de entrada (I) y salida (O) del revestimiento del vertedero.



**Figura 7.** Imágenes de la superficie desgastada de las muestras de prueba utilizadas para la validación de la estrategia computacional que evidencian cinco niveles de apariencia de desgaste. a) Desgaste leve (muestra de *R*), b) Desgaste abrasivo leve (muestra de *A*), c) Desgaste corrosivo, d) Desgaste abrasivo-corrosivo y e) Desgaste severo (muestras de *C*).



La observación de las superficies desgastadas sugirió que sólo un material de prueba ( $R$ ) tenía siempre la misma apariencia específica, mientras que otros materiales ( $A$ ,  $C$ ,  $C_m$  y  $E_m$ ) exhibían más de una característica de desgaste. Como ejemplo de esto, en la figura 7 se incluyeron tres imágenes de la superficie desgastada de la muestra de  $C$  para representar tres niveles diferentes de la severidad del desgaste (Desgaste-III a Desgaste-V). De esta manera, la apariencia de la muestra de  $R$  se caracteriza por pocas marcas de ranurado y corrosión (Figura. 7(a)), que era representativa del primer y más bajo nivel de severidad del desgaste (Desgaste leve). El segundo nivel de desgaste (Desgaste abrasivo leve) se presenta en la Figura. 7(b), en donde se observa la presencia de marcas de abrasión y carburos salientes, pero no se identificaron marcas de corrosión significativas. La Figura. 7(c) exhibe una superficie desgastada donde la corrosión se produjo de forma evidente y considerable, con la ausencia de abrasión (Desgaste corrosivo). En el cuarto nivel de desgaste (Desgaste corrosivo-abrasivo), las marcas de corrosión fueron acompañadas por los abrasivos (Figura. 7(d)). La Figura. 7(e) muestra el nivel de desgaste con la mayor severidad, donde se observan gruesos y profundos ranurados, junto con la evidencia de corrosión (Desgaste severo). La estrategia computacional propuesta ofrece la capacidad de reconocer estas características de la superficie y llevar a cabo una evaluación de los materiales de prueba para saber qué nivel de severidad de desgaste fue predominante.

## 6. DISEÑO EXPERIMENTAL

En este trabajo se realizaron dos aproximaciones computacionales que responden a dos problemas de caracterización de superficies diferentes. En primera instancia, se evaluó un esquema basado en gradientes (DAISY y HoG) que resultaba suficiente para la caracterización en laboratorio sobre imágenes *SEM* de superficies desgastadas por abrasión. En segunda instancia, se propuso una estrategia computacional para caracterizar los mecanismos de desgaste y la severidad sobre imágenes de una superficie desgastada en un vertedero. A continuación se especifican los parámetros y esquema de evaluación realizada en cada experimento.

### 6.1. VALIDACIÓN DAISY Y HOG

- ***Experimento en laboratorio sobre imágenes SEM***

La evaluación en este enfoque fue realizada para analizar el rendimiento de descriptores basados en gradientes: HoG y DAISY. Diferentes configuraciones en los descriptores fueron analizadas bajo un enfoque de validación *k-fold*. Específicamente, la validación estadística fue realizada utilizando diferentes conjuntos de particiones, definidos como:  $k = [2, 10, 20, 40]$ , permitiendo cubrir un rango amplio de modelos de aprendizaje SVM, contruidos a partir de diferentes proporciones de imágenes para el conjunto de entrenamiento. También, los resultados son reportados en términos de precisión que miden la porción de detección de verdaderos positivos sobre todo el conjunto de datos.

## 6.2. CONFIGURACIÓN Y AUMENTO DE LOS DATOS: REVESTIMIENTO DE VER- TEDERO

### ■ *Experimento in situ con superficies de revestimiento en vertedero*

En relación al conjunto de datos sobre el mecanismo de desgaste, las imágenes se redimensionaron al 80 % y se aplicó un suavizado utilizando un filtro gaussiano (tamaño del kernel de 5), lo que permitió eliminar los artefactos y ser más eficiente desde el punto de vista computacional durante la ejecución del enfoque propuesto. Además, las regiones media y de salida se consideraron en un mismo grupo ya que ambas regiones comparten los mismos mecanismos de desgaste y su distribución. Cada imagen fue dividida en parches cuadrados ( $c_w = c_h$ ), considerando dos dimensiones, 32 y 44 píxeles, respectivamente. Luego, cada imagen se representó usando alrededor de 1000 parches. Para el entrenamiento del algoritmo de aprendizaje de máquina *Random Forest* se consideró un aumento de los datos para ampliar la variabilidad de las clases y evitar el sobre ajuste en el modelo de clasificación. Para el aumento de datos se consideraron transformaciones geométricas aleatorias tales como: rotaciones (en un rango de [0-20] grados), desplazamientos verticales y horizontales (una proporción del 20 % con respecto a la imagen original) y reflexiones (en los ejes  $x$  e  $Y$ ). Diversas configuraciones de aumento de datos fueron evaluadas, considerando parches adicionales proporcionales al 20 %, 30 %, 40 % y 80 % del total de datos en cada experimento. El *Random Forest* fue entrenado siguiendo un criterio de impureza de *Gini* y se consideraron un total de 100 árboles en cada experimento para realizar la clasificación. Para la generación de mapas de desgaste se utilizó un valor de desplazamiento de ventana  $\delta$  de 20 píxeles, de modo que se puedan obtener mapas de desgaste con un menor costo de procesamiento.

En cuanto a la configuración del enfoque propuesto y la representación de las características profundas, en este trabajo se aplicaron dos arquitecturas convolucionales

de última generación: VGG16<sup>30</sup> y RESNET-50<sup>31</sup>. Por un lado, la VGG16 es una red profunda, ganadora del desafío ImageNet en 2013, con un total de 16 capas y filtros pequeños que preservan la información fina y granular, a lo largo de la representación jerárquica. Para esta red, como características profundas, se seleccionaron las activaciones que resultan del mapeado en la tercer y quinta capa obteniéndose un total de 64 y 512 filtros respectivamente. Por otro lado, la RESNET-50 fue la primera versión de redes muy profundas, evitando problemas de desvanecimiento de gradientes durante el entrenamiento, utilizando conexiones residuales que pasan información intercalada entre capas. Estas conexiones envían los mapas de características anteriores a la siguiente capa convolución como parámetro para un aprendizaje diferente de cero. A partir de esta red, se seleccionó la capa cinco para calcular como características profundas un total de 2048 filtros. A continuación, un análisis de componentes principales (*PCA-Principal Component Analysis*) resumió la información de los rasgos profundos, obteniendo un descriptor compacto con dimensiones entre 1024 y 4096 valores escalares para representar cada parche. En esta propuesta se utilizó el descriptor de HoG como línea base para representar cada uno de los parches extraídos de las imágenes.

### 6.3. MÉTRICAS DE VALIDACIÓN

El segundo enfoque, con características de aprendizaje profundo, teniendo en cuenta la capacidad de caracterizar tanto mecanismos de desgaste como grados de severidad. En ambas tareas se evaluó el enfoque de clasificación automática con una

---

<sup>30</sup> ZHANG, Xiangyu, *et al.* "Accelerating very deep convolutional networks for classification and detection". En: *IEEE transactions on pattern analysis and machine intelligence* 38.10 (2015), págs. 1943-1955. DOI: 10.1109/TPAMI.2015.2502579.

<sup>31</sup> HE, Kaiming, *et al.* "Deep residual learning for image recognition". En: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016, págs. 770-778.

estrategia de validación cruzada de “*leave-one-out*”, en la cual se dejó una imagen para probar y las restantes se utilizaron para entrenar el modelo empleando múltiples iteraciones. Teniendo en cuenta la clasificación del desgaste, también se evaluó la capacidad del método propuesto para obtener una reconstrucción del mapa de desgaste realizando un análisis global del fenómeno. Para evaluar cada una de estas tareas, se consideraron diferentes métricas, que se describen a continuación:

**6.3.1. Métricas de clasificación** A nivel de parche, para realizar la clasificación de los mecanismos de desgaste y severidad, cada clase considerada se evaluó en un esquema tal que para un mecanismo de desgaste o nivel de severidad  $X$  se define el número de verdaderos positivos (en inglés, *True Positive - TP*) como el número total de elementos de la clase  $X$  que fueron predichos correctamente en dicha clase. Los falsos positivos (en inglés, *False Positive - FP*) correspondientes al número total de elementos predichos con la clase  $X$  pero que realmente pertenecen a otra clase. Los falsos negativos (en inglés, *False Negative - FN*) representan el total de elementos de clase  $X$  predichos con cualquier otra clase. Utilizando esta configuración se establecieron las siguientes métricas:

- Exhaustividad(*Recall*):  $Re = \frac{TP}{TP+FN}$ , expresa la sensibilidad del enfoque propuesto para predecir adecuadamente una clase de desgaste/severidad, con respecto al total de elementos en dicha clase.
- Precisión:  $Pe = \frac{TP}{TP+FP}$  mide la proporción de clasificaciones correctas de desgaste/severidad, con respecto al total de etiquetas predichas para la clase de desgaste/severidad evaluada.
- Puntaje F1:  $F1 = 2 * \frac{Pe*Re}{Pe+Re}$  define la media armónica entre la métrica de precisión y la de recall, dando un resultado acorde la diferencia entre ambas métricas, penalizando el valor según la métrica con valor mas bajo.

**6.3.2. Métrica de Mapas de desgaste** Para validar la concordancia entre el mapa del mecanismo de desgaste y la anotación realizada para los expertos humanos, se consideró la siguiente métrica:

- *Dice score*  $DSC = \frac{2\|A \cap B\|}{\|A\| + \|B\|}$  mide el grado de intersección entre las anotaciones de desgaste y el estimado por el enfoque propuesto, con respecto al área total de ambas regiones comparadas. Esta medida permite estimar una superposición espacial de las áreas etiquetadas y las mapeadas para cada mecanismo de desgaste.


## 7. EVALUACIÓN Y RESULTADOS

### 7.1. CLASIFICACIÓN SOBRE IMÁGENES SEM USANDO DESCRIPTORES BASADOS EN GRADIENTE

La primera evaluación se llevó a cabo utilizando un descriptor HoG cambiando los parámetros principales del descriptor, i.e., número de orientaciones ( $o$ ), tamaño del parche en las imágenes ( $c$ ) y número de bloques ( $b$ ) utilizados para normalizar los histogramas. En la figura-8 se ilustra un resumen de los resultados obtenidos para diferentes configuraciones de HoG ( $o, c, b$ ) y bajo los diferentes esquemas de particiones  $k$ , según la configuración del  $K - fold$ . Se logró una precisión media máxima de 94% usando la configuración de  $o16, c32, b4$  y con una partición de  $k = 5$ . En otras palabras, una alta precisión ya se logra con valores reducidos de  $k$ , lo que implica mejores costos computacionales. El mismo resultado también se encontró antes, donde además se adquirió una menor dispersión de los datos y valores máximos similares de precisión con valores reducidos de  $k$  <sup>26</sup>. El clasificador *SVM* dio como resultado un comportamiento más estable de la precisión en comparación con el comportamiento observado anteriormente con el árbol de decisión y los modelos de clasificación Naive Bayes <sup>26</sup>. Entonces, el *SVM* tiene una estabilidad de precisión similar al comportamiento del modelo de *RF*.

En general, los mejores resultados se obtienen con 16 orientaciones en los histogramas y utilizando una normalización de bloques de 4. Esta configuración es suficiente para caracterizar gran parte de las superficies y permite predecir adecuadamente las clases de régimen de desgaste. Resultados similares se obtuvieron con el cálculo del descriptor *HoG* y aplicando otros clasificadores <sup>26</sup>, donde 16 orientaciones en los histogramas dan lugar a las más altas precisiones. Por otra parte, los parches de 64 elementos son suficientes para capturar patrones de gradiente que representan

**Figura 8.** Resultados de la precisión como una función de los parámetros del descriptor de HoG y  $k$  particiones.

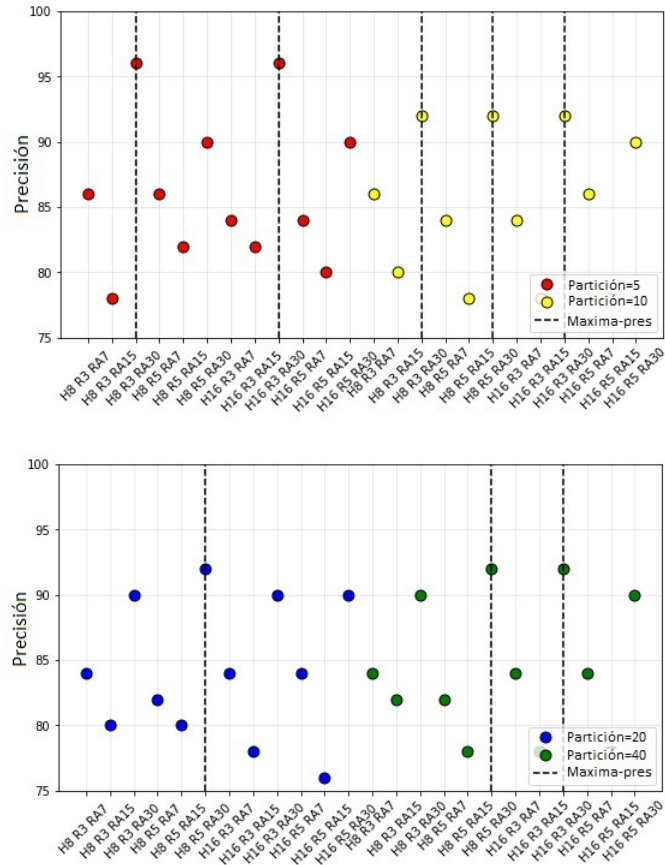


firmas de superficie desgastada. Debido a los fuertes cambios de gradientes que representan la severidad del desgaste, los histogramas con relativamente pocos bins son suficientes para representar distribuciones no uniformes. Básicamente, este descriptor se mantiene estable con casi todas las configuraciones, destacando los rasgos geométricos que caracterizan las superficies.

Se realizó una segunda evaluación del descriptor DAISY: para ello se codificaron las imágenes con diferentes variaciones en cuanto al número de histogramas calculados por anillo ( $h$ ), número de anillos utilizados en el descriptor ( $r$ ) y radio en píxeles de los anillos exteriores ( $ra$ ). En la figura-9 se muestran los resultados obtenidos por el descriptor DAISY utilizando diferentes configuraciones. En este caso, se encontró una precisión media máxima de 96% usando una partición  $k = 5$ , como se observó

para el descriptor HoG.

**Figura 9.** Rendimiento de el modelo en función de los parámetros del descriptor DAISY y las particiones.



Los mejores resultados de precisión se obtuvieron manteniendo el radio en píxeles de los anillos exteriores ( $ra$ ) en 30. No se observó ningún efecto en los parámetros de las otras configuraciones. Los resultados del descriptor DAISY muestran valores de precisión inestables, entre 75 % y 80 %.

Como se observa en los resultados anteriores, se lograron precisiones de casi el 95 % con los descriptores HoG y DAISY. Como consecuencia, hay algunas imágenes de superficies desgastadas que están siendo mal clasificadas. En otras palabras, algunas imágenes se están clasificando como "leves cuando son realmente

"severas", y viceversa. Entonces, se realizó un análisis para encontrar dichas imágenes y se encontró que eran las mismas tanto para el descriptor HoG como para DAISY. En la figura 4 se muestran imágenes mal clasificadas usando ambos descriptores de gradiente. Estas imágenes corresponden a superficies ligeramente desgastadas, pero el SVM las clasificó automáticamente como severas. Para entender este comportamiento, se debe discutir la apariencia de estas imágenes. En primer lugar, en la imagen de la izquierda se pueden observar algunas partículas blancas que tal vez no representen las marcas de desgaste presentes en la superficie, que tiene una baja cantidad de marcas producidas por los abrasivos, estas partículas podrían ser producto de contaminación ya que la superficie no presentaba un desgaste severo. Por el contrario, los rasgos superficiales de las imágenes del centro y de la derecha se caracterizan por muchos rasgos que justifican los resultados, es decir, representan un régimen de desgaste severo. Sin embargo, su tasa de desgaste no fue tan alta como para esas condiciones severas etiquetadas y probablemente se encontraban en la región de transición entre los regímenes de desgaste leve y severo. Este resultado sugiere que tal vez deba crearse una tercera etiqueta y analizarse en futuros trabajos, que correspondan a aquellas condiciones que no pertenecen a la clase "leve" ni "severa", sino que se encuentran entre ellas.

## **7.2. CARACTERIZACIÓN DE MECANISMOS DE DESGASTE EN EL REVESTIMIENTO DEL VERTEDERO**


El enfoque propuesto se evaluó con la finalidad de cuantificar la capacidad del modelo durante la etapa de clasificación y generación de mapas asociados al desgaste de en imagen. Para evaluar ambas tareas, se realizaron dos experimentos diferentes según las muestras utilizadas para el entrenamiento. En primer lugar, se aprendió un mapa totalmente supervisado de los mecanismos de desgaste a partir de varias imágenes para generar una reconstrucción regional a partir de la información glo-

bal. En segundo lugar, una clasificación pseudo supervisada permitió introducir una aplicación pertinente, a partir de la cual sólo se identifica un conjunto reducido de parches en una imagen particular y la aplicación podía reconstruir un mapa de mecanismos de desgaste para toda la imagen. Los resultados de ambos experimentos se muestran en las siguientes secciones.

**7.2.1. Clasificación supervisada** En este primer experimento, el enfoque se entrena a partir de imágenes de toda la región, lo que permite captar una gran variabilidad de los mecanismos de desgaste, que permiten predecir y generar un mapa de desgaste según las clases presentes en cada región del revestimiento. En este experimento se realizó en primer lugar una búsqueda exhaustiva de parámetros para ajustar el enfoque propuesto a las regiones particulares evaluadas. En tal caso, se compararon las predicciones de parches a partir de características obtenidas de un aprendizaje profundo con respecto a las obtenidas por un descriptor HoG. Los parámetros evaluados fueron el tamaño del parche, el desplazamiento de la ventana a lo largo de las imágenes de prueba, y particularmente la capa convolucional usada para formar el descriptor de desgaste. La figura-10 muestra los resultados obtenidos para la región de entrada del revestimiento en diferentes configuraciones para ambos enfoques y usando como referencia la métrica  $F1$ , que depende de las métricas  $Re$  y  $Pe$ . Además, también se muestra y se elige la mejor configuración con un criterio de los valores medios más altos y las desviaciones estándar más bajas para las tres puntuaciones de los mecanismos de desgaste. Como era de esperar, el enfoque implementado a partir de características profundas logra un buen desempeño durante la clasificación, justificado por la descripción completa y densa que incluye primitivas relacionadas con los gradientes, la apariencia y los patrones de textura no lineales. Así, la mejor puntuación del enfoque propuesto se logró con la configuración de parches con un tamaño de 44 píxeles, y desplazamiento de 32 píxeles. Se utilizaron las primeras capas que representa una descomposición espectral de los


patrones de desgaste observados. Cabe señalar que el mejor mecanismo previsto se asoció a la clase de incrustación de mineral de hierro, lo cual se puede explicar por la mayor superficie que ocupa dicho mecanismo en esta región, como se señaló en <sup>29</sup>. Para tal mecanismo se logró un valor  $F1$  de 74%. Además, el peor mecanismo de desgaste fue la indentación por impacto que alcanzó sólo un  $F1$  de 36%. Por lo tanto, la incrustación de mineral de hierro fue completamente dominante para esta región, mientras que la clase de indentación por impacto se observó en pequeñas áreas. En términos computacionales, esto es una limitación porque para algunos mecanismos de desgaste no hay suficiente información causando baja probabilidad en la predicción y reconstrucción de cada mecanismos. En cuanto al descriptor HoG, la mejor configuración se encontró con parches y desplazamiento de tamaño 32 píxeles, con un promedio  $F1$  de 51% para el mecanismo de indentación de impacto. En esta configuración, la mejor clase prevista fue también la incrustación de mineral de hierro con una diferencia significativa de aproximadamente 20% con respecto a los  $F1$  logrados por el enfoque propuesto utilizando características de aprendizaje profundo.

**Figura 10.** Búsqueda iterativa de parámetros para el enfoque de clasificación supervisada de la región de entrada del revestimiento utilizando características de aprendizaje profundo (izquierda) y el descriptor HoG (derecha). Los parámetros evaluados fueron el tamaño del parche, el desplazamiento de la ventana y las capa convolucional usada en el calculo de las características profundas.



Los resultados obtenidos para la región de media-salida se presentan en la Figura 11 usando el descriptor de características de aprendizaje profundo y el descriptor HoG, variando también el tamaño del parche, la ventana deslizante y la capa usada para generar las características profundas. Para esta región sólo están presentes dos mecanismos de desgaste y el enfoque propuesto también logra un rendimiento de predicción mucho mejor a nivel de parche en todas las configuraciones. Para esta región casi se lograron puntuaciones perfectas para ambos mecanismos de desgaste que utilizan características de aprendizaje profundo, hecho que justifica la adecuada separación de los límites de ambas clases. La mejor configuración se logró con un tamaño de parche y desplazamiento de 44 píxeles, usando la primera capa convolucional de la arquitectura *VGG16*. De tal configuración se logró un puntaje  $F1$  de 95 %. En contraste, el descriptor HoG sólo alcanza un puntaje  $F1$  de 69 % en la mejor configuración usando parches de 44 píxeles y un desplazamiento de 54 píxeles. Una vez más, las desviaciones estándar fueron altas para el descriptor HoG.

**Figura 11.** Búsqueda iterativa de parámetros para el enfoque de clasificación supervisada para la región de medio-salida del revestimiento usando características profundas (izquierda) y el descriptor HoG (derecha). Los parámetros evaluados fueron el tamaño del parche, el desplazamiento de la ventana y las capa convolucional usada en el calculo de las características profundas.



La tabla-1 resume los resultados logrados en la predicción de parches utilizando

tanto los rasgos profundos como el descriptor HoG en ambas regiones. La incrustación de mineral de hierro para la región de entrada, los fenómenos de corrosión (WM-IV) y el microcorte/arado (WM-V) para la región de medio-salida los mecanismos de desgaste fueron mejor caracterizados y, al mismo tiempo, fueron quienes tenían las mayores áreas correspondientes <sup>29</sup>. Este hecho se asocia a un problema de desequilibrio en el conjunto de datos, a partir del cual, las regiones más grandes tienen una mayor probabilidad de ser modeladas y pronosticadas correctamente. Por ejemplo, se logra una predicción adecuada en la región de medio-salida para ambas clases porque el enfoque propuesto tiene un equilibrio adecuado en las clases de desgaste para cada una de las imágenes evaluadas. En cambio, en la región de entrada, el microarado/corte superpuesto con incrustación de mineral de hierro (WM-III) logró sólo un 30 % para la medida del *recall* pero una notable precisión de 90 %. Esta diferencia se puede explicar teniendo en cuenta el reducido conjunto de muestras de entrenamiento con respecto a las demás clases. En general, el uso de características de aprendizaje profundo en el enfoque propuesto tiene una notable representación a nivel de parche que demuestra su eficacia en el modelado y caracterización de los mecanismos de desgaste.

**Tabla 1.** Desviaciones estándar y promedio de las métricas evaluadas para los mecanismos de desgaste del revestimiento usando características de aprendizaje profundo y el descriptor HoG. R: Región; WM: Mecanismos de desgaste; I: Región de entrada; MO: Región de medio-salida.

R	WM	Características profundas			HoG		
		<i>Re</i> [%]	<i>Pe</i> [%]	<i>F1</i> [%]	<i>Re</i> [%]	<i>Pe</i> [%]	<i>F1</i> [%]
I	WM-I	89 ± 2	71 ± 32	74 ± 24	73 ± 12	49 ± 9	51 ± 32
	WM-II	28 ± 20	52 ± 41	36 ± 26	15 ± 13	79 ± 11	14 ± 10
	WM-III	88 ± 9	48 ± 38	50 ± 36	15 ± 11	84 ± 2	19 ± 14
MO	WM-IV	95 ± 2	95 ± 2	98 ± 2	88 ± 8	66 ± 2	69 ± 22
	WM-V	93 ± 7	98 ± 4	94 ± 3	66 ± 2	88 ± 8	68 ± 12


Una segunda evaluación del experimento supervisado, fue la obtención de recons-

trucciones de mapas de desgaste mediante la predicción de la propagación en imágenes evaluadas. En la figura 12 se muestran imágenes originales de la superficie desgastada: (a) de tres regiones, con las correspondientes imágenes etiquetadas, (b) el mapeo supervisado utilizando características de aprendizaje profundo y (c) el descriptor *HoG* (d). En tal caso, el enfoque propuesto logra una notable reconstrucción que permite analizar globalmente los mecanismo de desgaste y comprender las tendencias del mismo que se propagan en el revestimiento del vertedero. En la tabla-2 se incluyen los resultados cuantitativos logrados para ambas metodologías con las anotaciones manuales. Notablemente, el enfoque que utiliza características profundas logra una medida de intersección (*dice score*) superior al 65 % para 3 los 5 mecanismos de desgaste evaluados. Como ya se ha mencionado, los mecanismos de desgaste que ocupan pequeñas áreas en la imagen (WM-II Y WM-III) son penalizados con una métrica de superposición deficiente y requieren de un análisis adicional para ajustar la sensibilidad del modelo. Contrario a esto, en la región de medio-salida, en la que se produjeron áreas equilibradas para los mecanismos de desgaste, se obtuvo una medida de similitud aceptable entre las regiones reconstruidas y las etiquetadas de forma manual.

**Tabla 2.** Desviaciones estándar y promedio de la métrica *DSC* para los mecanismos de desgaste del revestimiento usando características de aprendizaje profundo y el descriptor *HoG*. R: Región; WM: Mecanismos de desgaste; I: Región de entrada; MO: Región de medio-salida.

R	WM	Características profundas	HoG
		<i>DSC</i> [%]	<i>DSC</i> [%]
I	WM-I	66 ± 13	44 ± 12
	WM-II	31 ± 20	9 ± 6
	WM-III	47 ± 17	12 ± 7
MO	WM-IV	77 ± 7	60 ± 6
	WM-V	70 ± 20	40 ± 14

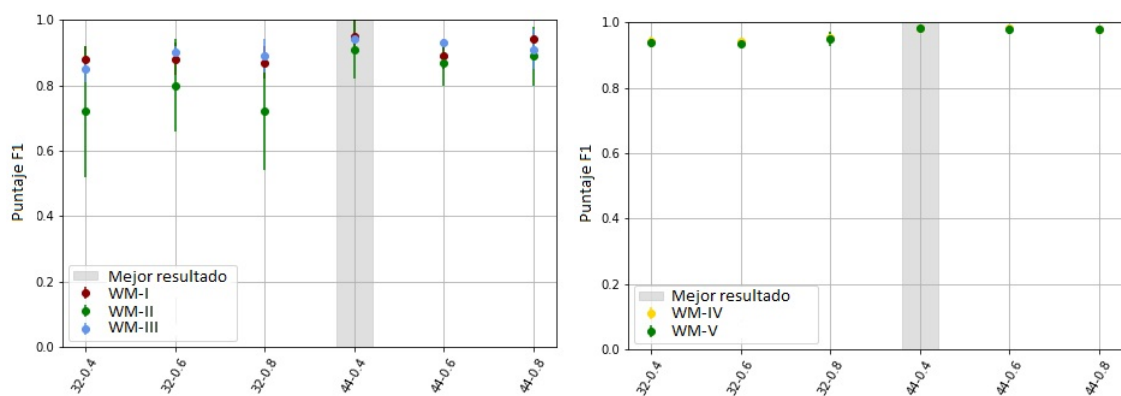
**Figura 12.** Mapeo de mecanismos de desgaste usado la mejor configuración y el enfoque de clasificación supervisada. Se incluyen imágenes originales de las superficies desgastadas (a) para ser comparadas con las imágenes etiquetadas correspondientes (b) y los mapas de mecanismos de desgaste obtenidos por el modelo de clasificación utilizando características de aprendizaje profundo (c) y el descriptor HoG (d).



**7.2.2. Clasificación pseudo-supervisada** Se desarrolló un segundo experimento para evaluar el rendimiento del enfoque propuesto al momento de propagar los mecanismos de desgaste a partir de un número mínimo de parches de la misma imagen (20% de los parches). Esta tarea pseudo-supervisada podría dar lugar a una aplicación práctica en la que sólo se identifiquen algunos puntos representativos, con los mecanismos de desgaste asociados, y el enfoque propuesto sería útil para propagar todo el mapeo de desgaste en la reconstrucción. En este experimento sólo se consideraron las características de aprendizaje profundo para realizar la tarea

pseudo-supervisada debido a la evaluación reportada en experimentos anteriores. Figura-13 muestra la búsqueda de algunos parámetros codificados como *cc\_ag* donde *cc* es el tamaño del parche y *ag* corresponde al porcentaje de aumento aplicado en cada experimento. El rendimiento en la clasificación de los mecanismos de desgaste se muestra para las regiones de entrada (izquierda) y medio-salida. Debido al reducido tamaño del conjunto de imágenes de entrenamiento, en este experimento es fundamental aplicar el aumento artificial de datos para tratar la representación de la variabilidad de los mecanismos de desgaste. En el enfoque propuesto, utilizando características de aprendizaje profundo, se logran resultados estables con métricas de hasta 96 % para diferentes configuraciones. Así, este experimento muestra mejor rendimiento en conjuntos de datos desbalanceado. La mejor configuración en ambas regiones se logró con un tamaño de ventana de 44 píxeles y un total de 40 % de imágenes generadas de forma artificial usando aumento de datos.

**Figura 13.** Búsqueda iterativa de parámetros para el enfoque de clasificación pseudo-supervisada de las regiones de entrada (izquierda) y de medio-salida (derecha) del revestimiento utilizando características de aprendizaje profundo. Los parámetros evaluados fueron, el tamaño del parche, el porcentaje de aumento de los datos aplicado sobre los parches, además La capa convolucional se mantuvo fija durante cada evaluación, usando la primera capa de la red VGG16.



La tabla-3 resume los resultados de las tres métricas consideradas en este enfoque. En general, todos los mecanismos de desgaste considerados en cada imagen se clasificaron correctamente con una puntuación media de hasta el 90 % para las

tres métricas. De hecho, no hubo diferencia entre los mecanismos de desgaste que mostraban distintas áreas ocupadas en cada una de las imágenes. Los mejores resultados se reportan nuevamente para la región de media-salida debido a la distribución correctamente balanceada y homogénea de los mecanismos de desgaste correspondientes en cada imagen.


**Tabla 3.** Desviaciones estándar y promedio de las métricas evaluadas para los mecanismos de desgaste de los revestimientos usando características de aprendizaje profundo. R: Región; WM: Mecanismos de desgaste; I: Región de entrada; MO: Region de media-salida.

R	WM	Características profundas		
		$R[\%]$	$Pe[\%]$	$F1[\%]$
I	WM-I	$93 \pm 5$	$81 \pm 11$	$86 \pm 8$
	WM-II	$76 \pm 20$	$95 \pm 3$	$83 \pm 14$
	WM-III	$96 \pm 12$	$90 \pm 6$	$93 \pm 3$
MO	WM-IV	$98 \pm 1$	$96 \pm 1$	$94 \pm 3$
	WM-V	$94 \pm 3$	$98 \pm 1$	$96 \pm 2$

Para este tipo de aprendizaje también se generaron mapas completos de los mecanismos de desgaste que representan la distribución espacial de las clases consideradas. En la figura 14 se ilustran varios ejemplos de mecanismos de desgaste reconstruidos. Como era de esperar, el enfoque propuesto logra una representación local adecuada de los mecanismos de desgaste, que podría ser fundamental para determinar la propagación de las clases a lo largo de la región. Algunas limitaciones están presentes en las fronteras espaciales de desgaste, que pueden estar asociados a la aproximación del nivel de parche.

Además, se realizó una evaluación cuantitativa de la estimación espacial de los mecanismos de desgaste con respecto a las anotaciones manuales. Una segmentación coherente se asocia en este experimento con una puntuación media de superposición del 71 %. La mejor puntuación se asocia a los fenómenos de corrosión, debido a que es el mecanismo con mayor presencia a lo largo del área de las imágenes de la región media y salida. En tal caso, la textura, el color y los bordes son adecuada-

**Figura 14.** Mapeo de mecanismos de desgaste usando la mejor configuración aplicada al enfoque de clasificación pseudo-supervisada. Se incluyen imágenes originales de las superficies desgastadas (a) para ser comparadas con las imágenes etiquetadas correspondientes (b) y el mapa del mecanismo de desgaste obtenido por el modelo de clasificación utilizando los rasgos obtenidos por aprendizaje profundo (c).



mente caracterizados para propagar este mecanismo de desgaste a lo largo de la imagen.

**Tabla 4.** Promedio y desviaciones estándar de la métrica  $DSC$  para los mecanismos de desgaste de los revestimientos usando características profundas. R: Región; WM: Mecanismos de desgaste; I: Región de entrada; MO: Regiones de media y salida.

R	WM	Características profundas
		$DSC[\%]$
I	WM-I	$73 \pm 13$
	WM-II	$65 \pm 9$
	WM-III	$69 \pm 14$
MO	WM-IV	$81 \pm 3$
	WM-V	$71 \pm 11$

### 7.3. CARACTERIZACIÓN DE LA SEVERIDAD DEL DESGASTE

Para validar la versatilidad y flexibilidad del modelo para representar diferentes patrones de superficie, se llevó a cabo una evaluación complementaria sobre un nuevo conjunto de datos con imágenes de superficies de revestimiento desgastadas probados en campo. En ese conjunto de datos la tarea consiste en tratar de predecir automáticamente diferentes niveles de severidad del desgaste en las superficies desgastadas de los materiales de prueba, lo que permite cuantificar el desgaste y determinar una clasificación de los materiales en cuanto a su resistencia al desgaste. En la tabla 5 se incluyen los resultados de las métricas de evaluación obtenidas durante la clasificación de los niveles de severidad del desgaste aplicando las características profundas y el descriptor *HoG*. Curiosamente, en el enfoque propuesto, utilizando características de aprendizaje profundo, se logra la sensibilidad adecuada para diferenciar entre los diferentes niveles de severidad del desgaste. En este caso, los valores de  $F1$  fueron relativamente altos para la mayoría de los niveles de severidad del desgaste utilizando características profundas, lo que representa valores tanto de  $Pe$  como de  $Re$ . No obstante, el nivel Desgaste-IV exhibe un valor bajo de  $F1$ , mientras que algunas desviaciones estándar de los valores de  $F1$  fueron altas. El desgaste leve y el abrasivo leve fueron los niveles mejor caracterizados de la severidad del desgaste debido a los patrones observados con respecto al color y la firma de la textura. En contraste, el descriptor *HoG* que sólo se basa en patrones de gradiente tiene varias limitaciones para representar los niveles de severidad del desgaste. Sólo el desgaste leve (Desgaste-I) fue reconocido de forma efectiva por este descriptor.

Aprovechando la excelente predicción de los niveles de severidad del desgaste, en un segundo experimento se evaluaron las imágenes del conjunto de datos sin etiquetar para conocer el nivel de severidad del desgaste en el que se clasificaron los materiales de prueba. La figura-15 presenta histogramas donde se cuenta el nivel

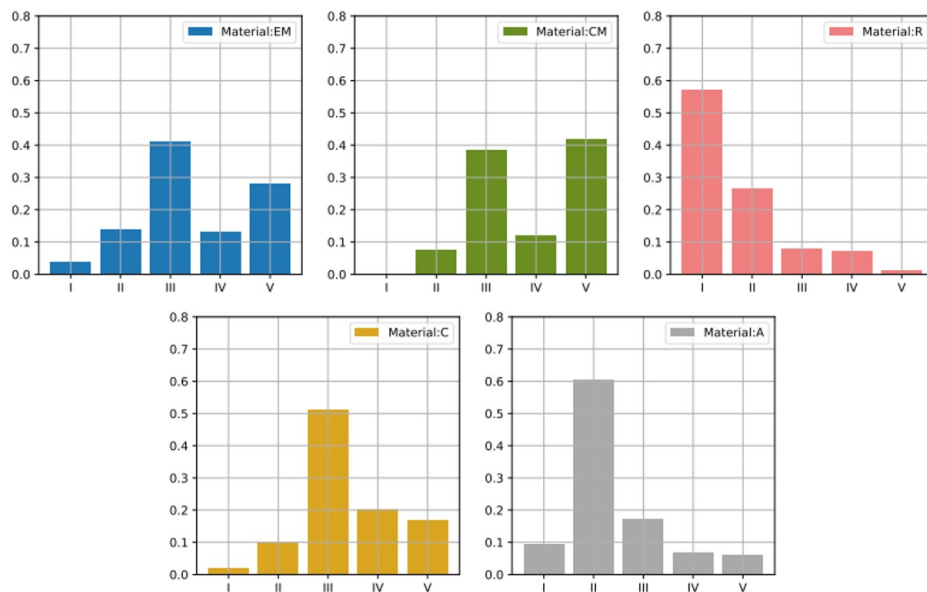
**Tabla 5.** Desviaciones estándar y promedio de las métricas evaluadas para la severidad del desgaste de los materiales de revestimiento usando características de aprendizaje profundo y el descriptor HoG. Desgaste-I: Desgaste leve; Desgaste-II: Desgaste abrasivo leve; Desgaste-III: Desgaste corrosivo; Desgaste-IV: Desgaste abrasivo-corrosivo; Desgaste-V: Desgaste severo.

Niveles de severidad	Características profundas			HoG		
	$Re$ [%]	$Pe$ [%]	$F1$ [%]	$Re$ [%]	$Pe$ [%]	$F1$ [%]
Desgaste-I	$82 \pm 18$	$99 \pm 1$	$88 \pm 13$	$100 \pm 0$	$21 \pm 1$	$34 \pm 1$
Desgaste-II	$70 \pm 32$	$61 \pm 25$	$64 \pm 25$	$9 \pm 7$	$69 \pm 41$	$15 \pm 11$
Desgaste-III	$64 \pm 22$	$58 \pm 5$	$59 \pm 11$	$0 \pm 0$	$0 \pm 0$	$0 \pm 0$
Desgaste-IV	$30 \pm 18$	$45 \pm 22$	$34 \pm 18$	$0 \pm 0$	$0 \pm 0$	$0 \pm 0$
Desgaste-V	$72 \pm 42$	$50 \pm 22$	$56 \pm 36$	$0 \pm 0$	$0 \pm 0$	$0 \pm 0$

de severidad para cada parche extraído de las imágenes del material de muestra . En general, los resultados son coherentes con respecto a las mediciones de pérdida de masa. Se encontró que el material  $R$  es el material más resistente al desgaste, como también se sugiere según el histograma correspondiente de este material, la mayoría de las clasificaciones se definieron en desgaste leve (Desgaste-I) y desgaste abrasivo leve (Desgaste-II). Otro material que presentaba una baja pérdida de masa es la muestra  $A$ , cuyo histograma muestra que gran parte de sus parches se clasificaban como desgaste abrasivo leve. Los demás materiales,  $C$ ,  $C_m$  y  $E_m$ , tienen un comportamiento de desgaste similar con una menor resistencia al desgaste que los materiales  $R$  y  $A$ . Esto se correlaciona con las predicciones del modelo propuesto, el cual clasificó a los primeros materiales en los niveles más severos de desgaste (Desgaste-III, Desgaste-IV y Desgaste-V). Como se mencionó en el capítulo 5.3, estos materiales fueron los únicos en los que se observaron diferentes características de desgaste, como lo confirman los resultados del análisis computacional. Estos resultados muestran que, aunque se obtuvieron algunas desviaciones estándar elevadas en las métricas estadísticas de evaluación, el rendimiento del modelo fue suficiente para reconocer los niveles de severidad del desgaste y señalar los materiales con alta resistencia al desgaste. Teniendo en cuenta lo anterior,

estos resultados apoyan el desarrollo de aplicaciones que permitan realizar la clasificación de los materiales en cuanto al comportamiento del desgaste y el análisis de la pérdida de masa. Siendo especialmente útiles para realizar el análisis de las pruebas de desgaste en el campo, donde la pérdida de masa de las muestras está fuertemente influenciada por los gradientes de desgaste <sup>32</sup> y es necesario identificar el comportamiento del desgaste a través de otras técnicas complementarias.

**Figura 15.** Histograma de clasificación para los niveles de severidad del desgaste aplicado los parches extraídos de las imágenes de materiales de prueba.



<sup>32</sup> BLICKENSDEFER, R. "Design criteria and correction factors for field wear testing". En: *Wear* 122.2 (1988), págs. 165-182. DOI: 10.1016/0043-1648(88)90076-2.

## 8. DISCUSIÓN

En este trabajo se presentaron y propusieron herramientas computacionales para la cuantificación y predicción de mecanismos de desgaste, observados como un conjunto de imágenes de superficies desgastadas. En el trabajo se presentaron dos métodos computacionales para dos conjunto de datos diferentes. En cuanto a pruebas de laboratorio y la evaluación de regímenes de desgaste, se evaluó la capacidad de los descriptores basados en gradientes para la predicción automática de estos desgastes. En imágenes *SEM*, en escala de grises, los descriptores basados en gradientes resultaron suficiente para la descripción de los mecanismos de desgaste observados por los efectos de la abrasión.

En un segundo enfoque computacional se demostró la efectividad del enfoque propuesto para reconocer y reconstruir los mapas de los mecanismos de desgaste y determinar niveles de severidad. Teniendo en cuenta un mayor desafío para la caracterización de los desgastes y una amplia variabilidad de las superficies con desgaste en el revestimiento, se propusieron vectores embebidos que resultaban de la caracterización local usando características de aprendizaje profundo. Estas herramientas ofrecen a los tribólogos un gran potencial para apoyar la caracterización de la superficie desgastada de una manera más completa, fiable, automática y cuantitativa.

Particularmente, para este trabajo se empleó un primer conjunto de imágenes de caracterización estereoscópica de revestimientos desgastados, en el que se analizaron dos regiones principales: la de entrada y la de media-salida. El enfoque de características de aprendizaje profundo se evaluó mediante la estimación de métricas y estadísticas de rendimiento, comparadas con los resultados obtenidos por el descriptor *HoG*. Adicionalmente, se optimizaron los parámetros de configuración de ambos enfoques para encontrar los mejores resultados. En el primer experimento se

aplicó una técnica de aprendizaje supervisado, en la que se emplearon imágenes completamente etiquetadas para entrenar el modelo. Los resultados confirmaron que el modelo propuesto realiza una mejor clasificación de los parches, teniendo en cuenta la descripción de características de gradientes, apariencia de la superficie y texturas particulares de cada mecanismo de desgaste. Este comportamiento fue además reflejado en los mapas generados de mecanismos de desgaste, ya que las características profundas reprodujeron con mayor precisión las áreas anotadas manualmente por el experto en tribología. La métrica del *DSC* demostró la mejor correlación entre las áreas dibujadas por expertos y las regiones estimadas usando el enfoque propuesto, con características de aprendizaje profundo, al menos para aquellos mecanismos de desgaste que ocupaban grandes áreas en la imagen. Se observó una limitación en cuanto al rendimiento del modelo al clasificar pequeñas áreas de mecanismos de desgaste en las imágenes evaluadas, donde las métricas estadísticas mostraban valores deficientes. Por consiguiente, Las áreas más grandes son las más destacadas durante la etapa de clasificación, ya que constituyen los procesos de desgaste dominantes. Por esta razón, es muy favorable que el modelo propuesto tienda a tener un mejor rendimiento en estas áreas. Los mecanismos de desgaste con áreas de acción pequeñas también podrían tener algún evento relevante en términos de respuesta de fricción durante el deslizamiento del mineral de hierro a través de la canaleta de transferencia. Por ejemplo, la incrustación de mineral de hierro identificada en la región de entrada del revestimiento podría ser consecuencia de la adhesión entre los minerales y la superficie del revestimiento, lo que podría promover bloqueos en la corriente de mineral y detener la producción de la planta. Desde este punto de vista, es importante continuar con la exploración y propuesta de nuevos modelos de aprendizaje de máquina para realizar una mejor caracterización de los mecanismos de desgaste, que contengan un número limitado de muestras de entrenamiento. En este sentido, un trabajo futuro podrá incluir el

análisis de eventos aislados, entendidos como procesos en aprendizaje de máquina poco ocurrentes con respecto a otras clases, es decir ponderando las clases con pocas muestras.

En este trabajo también se analizó el enfoque denominado reconstrucción pseudo-supervisada, en la cual sólo el 20% de los parches de imagen se usaron durante el proceso de entrenamiento. Esta técnica podría ser potencialmente aplicada en la industria cuando sólo se conoce con seguridad el desgaste que afecta una pequeña región de una imagen. Sorprendentemente, esta técnica obtuvo aún mejores resultados que los observados con la estrategia supervisada. En particular, esta técnica mejora, según las evaluaciones cuantitativas, la representación de los mecanismos de desgaste presentes en el revestimiento de la región de entrada. Así, esto supuso un punto importante para avanzar en el desafío de conseguir una mejor clasificación y mapeo de los mecanismos de desgaste con pequeñas áreas de contribución.

Para analizar la clasificación de la severidad del desgaste, se obtuvo un segundo conjunto de datos a partir de imágenes estereoscópicas de los materiales de muestra evaluados durante las pruebas de desgaste de un vertedero utilizado para el transporte del mineral de hierro. La clasificación de los niveles de severidad del desgaste se logró con el modelo de características de aprendizaje profundo propuesto, lo que sugiere que la representación profunda con un esquema jerárquico logra una apropiada descripción del desgaste en los materiales de los revestimientos de vertederos durante las pruebas realizadas. Sin embargo, las métricas obtenidas en este caso fueron variadas dependiendo de cada nivel de severidad. En concreto, los niveles de desgaste de menor severidad o de baja pérdida de masa asociada, mostraron los valores más altos, sugiriendo un rendimiento relativamente bueno de la tarea de clasificación.

## 9. CONCLUSIONES Y PERSPECTIVAS

En este trabajo se lograron plantear estrategias computacionales para soporte en el análisis y caracterización de superficies desgastadas. Inicialmente, en este trabajo presentó una estrategia de clasificación que es capaz de predecir regímenes leves y severos a partir de imágenes de superficies de desgaste. Las superficies de desgaste fueron totalmente caracterizadas utilizando un histograma denso de gradientes (*HoG*) y un descriptor eficiente y denso *DAISY*. El enfoque propuesto logró una clasificación aceptable, debido a la correcta representación de patrones de textura no uniformes de los regímenes de desgaste correspondientes. Los resultados de precisión obtenidos con el descriptor *HoG* fueron en su mayoría estables para las configuraciones evaluadas y lograron una precisión máxima del 95 %. Por su parte, el descriptor *DAISY* exhibió valores de precisión más inestables para los parámetros utilizados en su configuración y obtuvo una precisión máxima del 96 %.

En una segunda fase del trabajo, se logró proponer una estrategia que describe de forma robusta mecanismos de desgaste, presentes en un vertedero para el transporte de hierro, utilizando características de aprendizaje profundo. Estas características se obtienen en capas primarias de arquitecturas convoluciones pre-entrenadas. Una vez caracterizadas, se implementó el algoritmo *Random Forest* con el objetivo de realizar la clasificación automática de mecanismos de desgaste y niveles de severidad en imágenes. A partir del aprendizaje automático de mecanismos de desgaste fue posible generar mapas de desgaste que representaban regionalmente la propagación de cada clase en la imagen completa. Los mecanismos de desgaste que tenían suficientes muestras de entrenamiento mostraron resultados favorables tanto a nivel de predicción local, como su respectiva propagación en los mapas de desgaste. Cabe resaltar también que el experimento de aprendizaje pseudo-supervisado usando nada más el 20 % de las muestras, logrando una clasificación y propaga-

ción eficaz. Esta tarea puede ser extendida en aplicaciones prácticas donde resulta útil conocer la propagación del desgaste, pero su marcación manual resulta tediosa para los expertos. Trabajos futuros incluyen la implementación de sistemas funcionales y su evaluación por parte de un grupo de expertos y correspondiente validación microscópica. También se analizarán esquemas no supervisados para generar mecanismos de desgaste que apoyen y revelen patrones interesantes en el análisis de materiales.

## BIBLIOGRAFÍA

ABOUEL-KASEM, A, *et al.* “Fractal characterization of slurry eroded surfaces at different impact angles”. En: *Journal of Tribology* 131.3 (2009), pág. 31601. DOI: 10.1115/1.3118784 (vid. pág. 14).

AVERY, H S. “Materials for the mining industry”. En: *Symposium on Materials for the Mining Industry*. Ed. por R.Q. BARR. Vail, Colorado: Climax Molybdenum Company, 1974, págs. 43-78 (vid. pág. 12).

BLICKENSDEFER, R. “Design criteria and correction factors for field wear testing”. En: *Wear* 122.2 (1988), págs. 165-182. DOI: 10.1016/0043-1648(88)90076-2 (vid. pág. 60).

BODINI, I., *et al.* “Evaluation of wear in rolling contact tests by means of 2D image analysis”. En: *Wear* 400-401.December 2017 (2018), págs. 156-168. DOI: 10.1016/j.wear.2017.12.023 (vid. pág. 13).

BODINI, I, *et al.* “Evaluation of wear in rolling contact tests by means of 2D image analysis”. En: *Wear* 400-401 (2018), págs. 156-168. DOI: 10.1016/j.wear.2017.12.023 (vid. pág. 15).

CHANG, Chih Chung y LIN, Chih Jen. “LIBSVM: a library for support vector machines”. En: *ACM transactions on intelligent systems and technology (TIST)* 2.3 (2011), pág. 27 (vid. pág. 24).

CHANG, Haichuan; BORGHESANI, Pietro y PENG, Zhongxiao. “Automated assessment of gear wear mechanism and severity using mould images and convolutio-

nal neural networks”. En: *Tribology International* 147 (2020), pág. 106280. DOI: 10.1016/j.triboint.2020.106280 (vid. pág. 16).

CORONADO, J J; RODRÍGUEZ, S A y SINATORA, A. “Effect of particle hardness on mild-severe wear transition of hard second phase materials”. En: *Wear* 301.1-2 (2013), págs. 82-88. DOI: 10.1016/j.wear.2012.12.016 (vid. págs. 32, 33).

GONZALEZ-ARIAS, C., *et al.* “Automatic classification of severe and mild wear in worn surface images using histograms of oriented gradients as descriptor”. En: *Wear* 426-427 (2019), págs. 1702-1711. DOI: 10.1016/j.wear.2018.11.028 (vid. pág. 16).

GONZÁLEZ-ARIAS, C, *et al.* “Automatic classification of severe and mild wear in worn surface images using histograms of oriented gradients as descriptor”. En: *Wear* (Article in press, 2018). DOI: 10.1016/j.wear.2008.11.019 (vid. págs. 32, 45).

HAWK, Jeffrey A. “Abrasive wear testing”. En: *ASM Handbook Vol. 8. Mechanical Testing and Evaluation*. The Materials Information Society, 2000, págs. 694-728 (vid. pág. 12).

HE, Kaiming, *et al.* “Deep residual learning for image recognition”. En: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016, págs. 770-778 (vid. pág. 42).

HOLMBERG, Kenneth. “Tribological bases for accelerated testing”. En: *Operational reliability and systematic maintenance*. Ed. por A. HOLMBERG, K. FOLKESON. CRC Press, 1991. Cap. 1.2, págs. 31-50 (vid. pág. 12).

KIRK, T B, *et al.* “Computer image analysis of wear debris for machine condition monitoring and fault diagnosis”. En: *Wear* 181-183 (1995), págs. 717-722. DOI: 10.1016/0043-1648(95)90188-4 (vid. pág. 14).

KITTIPANYA-NGAM, Panachit y LUNG, Eng How. "HOG-based descriptors on rotation invariant human detection". En: *Asian Conference on Computer Vision*. Springer. 2010, págs. 143-152 (vid. pág. 22).

— "HOG-Based Descriptors on Rotation Invariant Human Detection". En: *Computer Vision – ACCV 2010 Workshops. ACCV 2010. Lecture Notes in Computer Science*. Ed. por Reinhard KOCH y Fay HUANG. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010, págs. 143-152. DOI: 10.1007/978-3-642-22822-3\_15 (vid. pág. 33).

MEYLAN, B, *et al.* "A simple, fast and low-cost method for in situ monitoring of topographical changes and wear rate of a complex tribo-system under mixed lubrication". En: *Wear* 364-365 (2016), págs. 22-30. DOI: 10.1016/j.wear.2016.06.006 (vid. pág. 15).

ONSOYEN, ELDAR. "Accelerated testing of components exposed to wear". En: *Operational Reliability and Systematic Maintenance*. Ed. por A. HOLMBERG, K. FOLKESSON. CRC Press, 1991. Cap. 1.3, págs. 51-78 (vid. pág. 12).

PODSIADLO, P. y STACHOWIAK, G. W. "Characterization of surface topography of wear particles by SEM stereoscopy". En: *Wear* 206.1-2 (1997), págs. 39-52. DOI: 10.1016/S0043-1648(96)07324-3 (vid. pág. 15).

RAWERS, J y TYLCZAK, J. "Fractal characterization of wear-erosion surfaces". En: *Journal of Materials Engineering and Performance* 8.6 (1999), págs. 669-676. DOI: 10.1361/105994999770346431 (vid. pág. 14).

SOLEIMANI, Seyfollah, *et al.* "Quantifying abrasion and micro-pits in polymer wear using image processing techniques". En: *Wear* 319.1-2 (2014), págs. 123-137. DOI: 10.1016/j.wear.2014.07.018 (vid. págs. 14, 15).

SUKUMARAN, J, *et al.* “High-speed imaging for online micrographs of polymer composites in tribological investigation”. En: *Wear* 296.1-2 (2012), págs. 702-712. DOI: 10.1016/j.wear.2012.08.016 (vid. págs. 14, 15).

TASAN, Y C; DE ROOIJ, M B y SCHIPPER, D J. “Measurement of wear on asperity level using image-processing techniques”. En: *Wear* 258.1-4 (2005), págs. 83-91. DOI: 10.1016/j.wear.2004.05.018 (vid. pág. 15).

TIBSHIRANI, Robert y HASTIE, Trevor. “Margin Trees for High-dimensional Classification”. En: *Journal of Machine Learning Research* 8 (2007), págs. 637-652 (vid. pág. 29).

TOLA, Engin; LEPETIT, Vincent y FUA, Pascal. “Daisy: An efficient dense descriptor applied to wide-baseline stereo”. En: *IEEE transactions on pattern analysis and machine intelligence* 32.5 (2010), págs. 815-830 (vid. pág. 33).

VALENZUELA, Brayan; VIÁFARA, Cristian y MARTÍNEZ, Fabio. “Analysis of worn surface images using gradient-based descriptors”. En: *2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA)*. IEEE. 2019, págs. 1-5. DOI: 10.1109/STSIVA.2019.8730247 (vid. pág. 16).

VALENZUELA, Brayan; VIÁFARA, Cristian y MARTÍNEZ, Fabio. “Analysis of worn surface images using gradient-based descriptors”. En: *2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA)*. IEEE. 2019, págs. 1-5 (vid. pág. 21).

VIÁFARA, Cristian Camilo, *et al.* “Wear modes and mechanisms in chute linings: An advance in their understanding from the characterization of worn linings supported by computer vision tools”. En: *in preparation* (2020) (vid. págs. 34, 50, 52).

WANG, S., *et al.* “Integrated model of BP neural network and CNN algorithm for automatic wear debris classification”. En: *Wear* 426-427. September 2018 (2019), págs. 1761-1770. DOI: 10.1016/j.wear.2018.12.087 (vid. pág. 16).

ZHANG, J. “Detection and monitoring of wear using imaging methods”. Tesis doct. University of Twente, 2006 (vid. pág. 15).

ZHANG, Xiangyu, *et al.* “Accelerating very deep convolutional networks for classification and detection”. En: *IEEE transactions on pattern analysis and machine intelligence* 38.10 (2015), págs. 1943-1955. DOI: 10.1109/TPAMI.2015.2502579 (vid. pág. 42).

ZUM GAHR, K.H. *Microstructure and wear of materials*. Vol. 10. Elsevier, 1987 (vid. pág. 12).

## APÉNDICES

### Anexo A. Productos Académicos

- Valenzuela, B., Viáfara, C., Martínez, F. (2019, April). Analysis of worn surface images using gradient-based descriptors. In 2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA) (pp. 1-5).
- IEEE.best quality paper on the topic: Machine Learning and Pattern Recognition.In 2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA)
- B. Valenzuela, C.C.Viáfara, J.J. Penagos, F. Martínez. “Wear mapping by propagating regional labels coded as embedding deep learning vectors”. Para ser enviados a Wear Elseiver  
Estado:En revisión por los autores.
- C.C. Viáfara,B. Valenzuela,F. Martínez,J.J. Penagos. “Tribology systems in transfer chute linings of the mining industry: Characterization of worn linings supported by computer vision tools”. Para ser enviados a Wear Elseiver  
Estado:En revisión por los autores.