



Evaluación de técnicas de preprocesamiento y clasificación automática (Random Forest y Decisión Tree) en imágenes digitales de fisuras y grietas en concreto.

Modalidad: Proyecto de investigación

Andrés Felipe Castillo Forero.

CC: 1.006.409.185.

Sergio Andrés Claro Toro

CC: 1.004.859.896

UNIDADES TECNOLÓGICAS DE SANTANDER

FCNI

Ingeniería Electromecánica

Bucaramanga

06/11/2025



Evaluación de técnicas de preprocesamiento y clasificación automática (Random Forest y Decisión Tree) en imágenes digitales de fisuras y grietas en concreto.
Modalidad: Proyecto de investigación

Andrés Felipe Castillo Forero.

CC: 1.006.409.185.

Sergio Andrés Claro Toro

CC: 1.004.859.896

Trabajo de Grado para optar al título de
Ingeniería Electromecánica.

DIRECTOR

Camilo Leonardo Sandoval Rodríguez.

Grupo de Investigación en Sistemas de Energía, Automatización y Control – GISEAC

UNIDADES TECNOLÓGICAS DE SANTANDER

FCNI

Ingeniería Electromecánica

Bucaramanga

06/11/2025


F-DC-125

INFORME FINAL DE TRABAJO DE GRADO EN MODALIDAD DE
PROYECTO DE INVESTIGACIÓN, DESARROLLO TECNOLÓGICO,
MONOGRAFÍA, EMPRENDIMIENTO Y SEMINARIO

VERSIÓN: 2.0

Aprobado cumpliendo todos los requisitos exigidos por el comité de trabajos de grado
de ingeniería electromecánica según acta numero 33 del 09 de diciembre de 2025

Carlos Gerardo Cárdenas Arias


Firma del Evaluador

Camilo Leonardo Sandoval Rodríguez


Firma del Director:

DEDICATORIA

Dedico este proyecto y todo mi proceso de formación académica, en primer lugar, a Dios, por ser mi guía, mi fortaleza y el pilar espiritual que me acompañó en cada etapa de este camino.

A mis padres Juliette Forero y Roland Castillo; a mi hermano Nicolás Castillo, cuyo apoyo incondicional, consejos, enseñanzas y palabras de aliento hicieron posible recorrer este camino con dedicación y excelencia. Gracias por creer en mí, por impulsarme a dar siempre lo mejor y por ser el motor que me permitió culminar con éxito cada uno de mis objetivos.

Andrés Felipe Castillo Forero.

Quiero dedicarles principalmente este triunfo a mis padres, Edgar Claro y Hermelinda Toro; ustedes son el cimiento sobre el cual he construido cada uno de mis sueños. Este trabajo es el reflejo de su amor incondicional, de sus sacrificios silenciosos y de su fe inquebrantable en mí.

A mi madre, por ser mi refugio y mi fuerza, por sus palabras de aliento en los días grises y por creer en mí incluso cuando yo dudaba. A mi padre, por su ejemplo de perseverancia, por su esfuerzo incansable y por enseñarme con hechos que no hay meta que no se pueda alcanzar con dedicación.

Les dedico este logro, porque es tan suyo como mío. Gracias por ser mi motor y mi inspiración eterna.

Sergio Andrés Claro Toro.

AGRADECIMIENTOS

A Dios, por brindarme la sabiduría, la fortaleza y la guía necesarias para superar cada desafío que se presentó en este camino académico. Su presencia ha sido mi principal sostén y mi fuente de inspiración constante. A mi familia, por su amor incondicional, su apoyo permanente y por ser mi mayor motivación. Gracias por cada palabra de aliento, por cada sacrificio y por creer firmemente en mi capacidad para alcanzar mis metas. A mis compañeros, por compartir conmigo este proceso lleno de retos y aprendizajes. Por el trabajo en equipo, por la amistad y por cada momento que contribuyó a mi crecimiento personal y profesional. A mis maestros, quienes con su entrega, conocimientos y vocación marcaron profundamente mi formación. Gracias por orientarme, exigirme y guiarme con dedicación hacia el logro de este objetivo.

Andrés Felipe Castillo Forero.

El presente trabajo es el resultado de un proceso de formación que no hubiera sido posible sin el valioso aporte de instituciones y personas a quienes deseo expresar mi sincera gratitud. En primer lugar, agradezco a las Unidades Tecnológicas de Santander y a la Facultad de Ciencias Naturales e Ingeniería, por brindarme las herramientas y el espacio para mi desarrollo profesional. Mi reconocimiento se extiende a todos los docentes que, a lo largo de mi carrera, compartieron sus conocimientos y pasión por la Ingeniería Electromecánica. Su guía fue fundamental para forjar el criterio necesario para la realización de este proyecto.

De manera especial, agradezco a mis compañeros de estudio, quienes se convirtieron en un pilar de apoyo colaborativo. Sus diferentes perspectivas, la mutua colaboración en momentos clave y la camaradería durante estos años fueron indispensables para culminar con éxito esta etapa.

Sergio Andrés Claro Toro.

TABLA DE CONTENIDO

RESUMEN EJECUTIVO.....	9
INTRODUCCIÓN.....	10
1. DESCRIPCIÓN DEL TRABAJO DE INVESTIGACIÓN	13
1.1. PLANTEAMIENTO DEL PROBLEMA.....	13
1.2. JUSTIFICACIÓN.....	15
1.3. OBJETIVOS.....	16
1.3.1. OBJETIVO GENERAL.....	16
1.3.2. OBJETIVOS ESPECÍFICOS.....	16
1.4. ESTADO DEL ARTE.....	16
2. MARCO REFERENCIAL	20
3. DISEÑO DE LA INVESTIGACIÓN.....	24
4. DESARROLLO DEL TRABAJO DE GRADO	26
5. RESULTADOS	33
6. CONCLUSIONES	35
7. REFERENCIAS BIBLIOGRÁFICAS	36

LISTA DE FIGURAS

Figura 1. Imágenes base de datos.	26
Figura 2. Imágenes Procesadas.....	27
Figura 3. Decision Tree HOG vs LBP.....	29
Figura 4. Random Forest HOG vs LBP.	30
Figura 5. Decision Tree HOG vs GLCM.	30
Figura 6. Random Forest HOG vs GLCM.....	31
Figura 7. Decision Tree LBP vs GLCM.....	31
Figura 8. Random Forest LBP vs GLCM.	32

LISTA DE TABLAS

Tabla 1. Métricas de los diferentes clasificadores.....	33
--	----

RESUMEN EJECUTIVO

El presente trabajo tiene como objetivo diseñar y evaluar un modelo de clasificación automática de fisuras y grietas en estructuras de concreto, mediante la integración de algoritmos supervisados (Random Forest y Decision Tree) y técnicas de preprocesamiento de imágenes. Esta propuesta busca contribuir al desarrollo de sistemas de inspección estructural automatizados, especialmente en entornos urbanos colombianos donde el deterioro de edificaciones por envejecimiento, actividad sísmica o falta de mantenimiento es una problemática creciente.

La metodología adoptada se enmarca en un enfoque cuantitativo, con un diseño experimental basado en procesamiento digital de imágenes y clasificación supervisada. Se recopilaron imágenes de concreto fisurado, las cuales fueron sometidas a técnicas de preprocesamiento como binarización, ajuste de contraste y detección de bordes. Posteriormente, se extrajeron características morfológicas (área, longitud, orientación) y texturales (HOG, LBP, GLCM), que sirvieron como vectores de entrada para los modelos de clasificación.

Los algoritmos Random Forest y Decision Tree fueron entrenados y validados utilizando conjuntos de datos etiquetados. El desempeño de los modelos se evaluó mediante métricas como precisión, sensibilidad, especificidad y matriz de confusión. Los resultados obtenidos muestran que ambos clasificadores alcanzan niveles aceptables de exactitud, siendo Random Forest el modelo con mejor desempeño general, especialmente en escenarios con ruido o variabilidad en la iluminación.

PALABRAS CLAVE. Clasificación supervisada, fisuras en concreto, procesamiento de imágenes, Random Forest, Decision Tree.

INTRODUCCIÓN

En Colombia, muchas edificaciones urbanas fueron construidas hace algunos años bajo normativas técnicas que hoy resultan insuficientes frente a las exigencias estructurales actuales. El envejecimiento de materiales, la exposición a condiciones climáticas extremas, la actividad sísmica en zonas como el Santander y la falta de mantenimiento periódico han generado un aumento en la aparición de fisuras y grietas en muros, columnas y losas de concreto. Estos defectos superficiales, aunque inicialmente pueden parecer menores, representan señales tempranas de deterioro que, si no se detectan y corrigen oportunamente, pueden comprometer la estabilidad de las construcciones. Casos como el colapso de la torre del puente Chirajara en 2018 —atribuido a fallas de diseño estructural— han puesto en evidencia la necesidad de fortalecer los sistemas de inspección y monitoreo en obras civiles, incluso en etapas constructivas.

El monitoreo de salud estructural (SHM, por sus siglas en inglés) se ha consolidado como una herramienta clave para la evaluación continua del estado de las obras civiles. Este enfoque permite detectar daños como fisuras, desprendimientos, corrosión o deformaciones, mediante técnicas que van desde inspecciones visuales hasta ensayos no destructivos (NDT), como ultrasonido, radiografía o termografía infrarroja. No obstante, estos métodos tradicionales requieren personal especializado, son costosos y presentan limitaciones en cobertura y frecuencia de aplicación, especialmente en regiones rurales o de difícil acceso.

Los avances recientes en sensores ópticos, procesamiento digital de imágenes y algoritmos de clasificación han permitido desarrollar sistemas automatizados para la detección de fisuras en concreto. Las técnicas de visión por computadora, tanto tradicionales como basadas en aprendizaje profundo, han demostrado ser eficaces para identificar patrones visuales asociados a daños

superficiales. En particular, las redes neuronales convolucionales (CNN) han alcanzado altos niveles de precisión en tareas de clasificación y segmentación de fisuras. Por ejemplo, (Islam et al., 2022) desarrollaron un enfoque basado en transferencia de aprendizaje con modelos preentrenados como ResNet18, DenseNet161, VGG16 y AlexNet, logrando una clasificación eficiente de fisuras en superficies de concreto. Asimismo, (Wu et al., 2021) utilizaron los modelos GoogleNet e Inception V3 para mejorar la detección de grietas en imágenes, demostrando que el ajuste fino de redes pre-entrenadas puede aumentar la precisión en contextos visuales complejos. (Zhu & Song, 2020) por su parte, optimizaron la arquitectura VGG-16 para evaluar defectos superficiales en puentes de concreto, comparándola con modelos tradicionales como SVM y redes neuronales de retropropagación. Estas investigaciones evidencian el potencial de las CNN para extraer características multicapas, enfatizando bordes y texturas relevantes para la clasificación. Sin embargo, el entrenamiento de estas arquitecturas requiere grandes volúmenes de datos etiquetados, recursos computacionales significativos y presentan baja interpretabilidad, lo que limita su aplicación en entornos operativos con restricciones técnicas.

En este contexto, se plantea la necesidad de explorar modelos de clasificación más ligeros, explicables y eficientes, que puedan integrarse en sistemas de inspección estructural automatizados. Este trabajo propone el diseño y evaluación de un modelo de clasificación automática de fisuras y grietas en estructuras de concreto, mediante la integración de algoritmos supervisados como Random Forest y Decision Tree, junto con técnicas de preprocesamiento de imágenes. Se emplean descriptores morfológicos y texturales (HOG, LBP, GLCM) para representar cuantitativamente las discontinuidades, y se evalúa el desempeño de los modelos mediante métricas como precisión, sensibilidad y matriz de confusión.

El enfoque propuesto busca ofrecer una solución adaptable a las condiciones operativas del país, con potencial de implementación en sistemas móviles, drones o estaciones de monitoreo visual, contribuyendo así al fortalecimiento de la gestión de infraestructura vial y estructural en Colombia.

1. DESCRIPCIÓN DEL TRABAJO DE INVESTIGACIÓN

1.1. PLANTEAMIENTO DEL PROBLEMA

En el contexto de mantenimiento predictivo de infraestructuras civiles, la inspección manual de fisuras o grietas en estructuras de concreto y pavimento presentan limitaciones significativas en términos de eficiencia, objetividad y cobertura espacial. Esta situación se agrava en entornos urbanos con alta densidad de tráfico, iluminación variable y presencia de sombras, donde los métodos tradicionales fallan en detectar grietas finas o parcialmente ocultas (Marín-Acevedo, 2020).

La problemática surge de la insuficiencia de los sistemas automatizados actuales para clasificar con precisión las fisuras en imágenes digitales, especialmente cuando se enfrentan a ruido visual, texturas complejas o condiciones de iluminación adversas. Aunque existen algoritmos como CrackForest, su desempeño se ve limitado por la pérdida de información estructural y la sensibilidad a parámetros de segmentación (Lozano, 2020).

Esta debilidad metodológica afecta directamente la toma de decisiones en mantenimiento estructural, generando retrasos, sobrecostos y riesgos operativos. Por ello, se plantea integrar técnicas de clasificación supervisada (Random Forest, Decision Tree) con estrategias de preprocesamiento robustas, como eliminación de sombras o binarización, para mejorar la detección automática de fisuras y grietas (Zoubir et al., 2022).

Se requiere un enfoque metodológico que permita comparar el rendimiento de distintos algoritmos bajo condiciones controladas y reales, evaluando métricas como precisión, sensibilidad y F1-score. Esta comparación permitirá establecer criterios técnicos para la adopción de modelos en sistemas de inspección

automatizada, alineados con los objetivos de sostenibilidad y eficiencia operativa.
¿Qué combinación de técnicas de clasificación y preprocesamiento permite una
detección robusta de fisuras y grietas en concreto en entornos urbanos?

1.2. JUSTIFICACIÓN

La detección automática de fisuras y grietas en estructuras de concreto representa una necesidad en el mantenimiento predictivo de infraestructuras civiles, especialmente en entornos urbanos donde las condiciones visuales dificultan la inspección manual. Resolver esta problemática permite mejorar la eficiencia operativa, reducir riesgos estructurales y optimizar recursos técnicos y económicos (Lozano, 2020).

La propuesta se fundamenta en la integración de algoritmos de clasificación supervisada (Random Forest, Decision Tree) con técnicas de preprocesamiento robustas, como eliminación de sombras o binarización, para lograr una clasificación precisa entre fisuras y grietas. Esta diferenciación es clave para establecer prioridades de intervención y evaluar la severidad del daño (Espillco Quintanilla, 2024; Zoubir et al., 2022).

Desde el punto de vista tecnológico, el proyecto promueve el desarrollo de sistemas inteligentes de inspección estructural, compatibles con drones o cámaras móviles. En lo económico, reduce costos asociados a inspecciones manuales y fallos no detectados. En lo social, contribuye a la seguridad ciudadana y a la sostenibilidad de la infraestructura pública.

Para las UTS, esta propuesta alimenta la investigación en procesamiento digital de imágenes y aprendizaje automático aplicada al diagnóstico estructural, fortaleciendo el vínculo entre ingeniería y tecnología emergente del grupo GISEAC. Además, permite al estudiante aplicar sus conocimientos en MATLAB, clasificación supervisada y síntesis crítica de literatura científica, generando un aporte real al campo de la mecatrónica y la robótica.

1.3. OBJETIVOS

1.3.1. OBJETIVO GENERAL

Diseñar y evaluar un modelo de clasificación automática de fisuras y grietas en estructuras de concreto, mediante la integración de algoritmos supervisados (Random Forest y Decision Tree) y técnicas de preprocesamiento de imágenes, con el fin de mejorar la detección en sistemas de inspección estructural.

1.3.2. OBJETIVOS ESPECÍFICOS

- Seleccionar técnicas de preprocesamiento relevantes para mejorar la visibilidad de fisuras y grietas en imágenes digitales.
- Implementar los algoritmos Random Forest y Decision Tree sobre conjuntos de imágenes preprocesadas.
- Evaluar el desempeño de los modelos mediante métricas cuantitativas, para determinar su capacidad de clasificación en escenarios reales.

1.4. ESTADO DEL ARTE

A continuación, se presentan los diferentes artículos en los cuales trabajaron con clasificación y extracción de características, para tratar imágenes.

El Artículo publicado describe un procedimiento para categorizar imágenes de grietas en estructuras de concreto, integrando descriptores HOG y ULBP junto con una reducción de dimensiones usando KPCA. Se analizaron más de 3000 fotos, las cuales fueron tratadas con un filtro mediano y convertidas a escala de grises. A través de KPCA, se logró reducir miles de atributos a solo 100 componentes significativos. Se evaluaron tres tipos de clasificadores: SVM, Random Forest y Árboles de Decisión. El modelo SVM con las características combinadas logró una precisión del 99.26%. Esta propuesta mejora la diferenciación de clases y disminuye el costo computacional. Este método apoya el uso de técnicas texturales

y no lineales en la evaluación estructural. Es muy útil para iniciativas de clasificación supervisada en concreto (Zoubir et al., 2022).

Este artículo propone un enfoque novedoso para detectar fisuras en superficies de concreto mediante técnicas de hashing y clasificación con Random Forest. Se evaluaron cinco algoritmos de hashing, incluyendo dos basados en wavelets, y se aplicó la transformada Z para mejorar la extracción de características. Se compararon 17 clasificadores de scikit-learn, destacando Random Forest con una precisión del 99%. Nueve de las diez características extraídas demostraron alta relevancia. El método es eficiente en memoria y procesamiento, ideal para aplicaciones embebidas como drones de inspección. La propuesta demuestra que el hashing puede ser competitivo frente a técnicas tradicionales. Es aplicable a sistemas de diagnóstico estructural automatizado (Frias & Hidalgo, 2021).

Este trabajo investiga la identificación de grietas en el concreto mediante el uso de imágenes de baja resolución y clasificadores como KNN, ANN y Árboles de Decisión (DT) (Rashid & Mokji, 2022). Se llevaron a cabo entrenamientos de modelos con resoluciones que iban de 50×50 a 5×5 píxeles, evidenciando que DT mantiene una alta precisión aun con imágenes pequeñas. El clasificador DT logró un nivel de precisión del 95% con imágenes de 50×50 y del 90% con las de 5×5, superando a KNN y ANN. Se aplicó interpolación por vecino más cercano para disminuir el tamaño de las imágenes sin comprometer el contorno de la grieta. La evaluación se fundamentó en criterios como precisión, recall y F1-score. Esta metodología es efectiva y puede ser utilizada en sistemas de vigilancia estructural. Se resalta la posibilidad de emplear DT en situaciones de baja calidad visual.

Este estudio propone un método para evaluar daños internos en concreto armado mediante Random Forest, usando datos de pruebas no destructivas como permeabilidad al aire, resistividad eléctrica, velocidad ultrasónica y resistencia a la compresión. Se entrenó el modelo con 392 muestras, inducidas con corrosión controlada, logrando una precisión alta ($R^2 = 0.89$, RMSE = 0.52). La resistividad

eléctrica fue el parámetro más relevante (peso relativo 0.907). El modelo detectó daños invisibles en puentes reales, demostrando su aplicabilidad práctica. Se utilizó validación cruzada LOOCV para evitar sobreajuste. El enfoque permite integrar múltiples pruebas para diagnóstico estructural confiable. Es altamente compatible con tu propuesta basada en Random Forest (Chun et al., 2020).

Este trabajo se centra en la identificación automática de fisuras en concreto utilizando técnicas de aprendizaje automático, enfrentando la dificultad de diferenciar grietas auténticas de patrones parecidos (sombras, manchas, espacios) (Kim et al., 2019). Se introduce un método que utiliza la binarización de imágenes para identificar áreas posibles, seguido de la clasificación usando Speeded-Up Robust Features (SURF) y redes neuronales convolucionales (CNN). Este método optimiza la identificación de fisuras en fotografías reales, superando las limitaciones de métodos convencionales. Se llevó a cabo una evaluación tanto cuantitativa como cualitativa con imágenes nuevas, mostrando una gran precisión en la distinción entre fisura y ruido. Esta metodología es valiosa para la inspección estructural automatizada. Adicionalmente, complementa su enfoque supervisado y refuerza la fase de preprocesamiento en los sistemas de clasificación.

El artículo propone un algoritmo híbrido paralelo que combina CNN pre entrenada para extracción de características con Random Forest como clasificador (Kyal et al., 2021). Se introduce una técnica novedosa de selección paralela de atributos para reducir redundancia y acelerar el procesamiento. Las características se extraen de múltiples capas concatenadas, y se aplica el modelo MPI para lograr paralelismo. El enfoque mejora significativamente el tiempo de ejecución y la precisión en la detección de grietas en concreto.

Este estudio propone un modelo automatizado para inspección de estructuras de concreto mediante CNN y procesamiento de imágenes con Otsu. Se entrenó con 40,000 imágenes para clasificar grietas según orientación (horizontal, vertical, izquierda, derecha) y cuantificarlas en longitud, ancho y ángulo. El modelo

alcanzó precisiones superiores al 97% y errores de cuantificación menores al 5%. Se destaca por su capacidad para identificar tipo y severidad del daño estructural según normas internacionales. Es aplicable a inspección con drones y sistemas de mantenimiento predictivo (Flah et al., 2020).

(Wang et al., 2024) propone un método automático para detectar grietas en pavimentos combinando Random Structure Forest con clustering por densidad (DBSCAN). Se introduce una técnica de eliminación de sombras basada en partición de brillo para mejorar la visibilidad de grietas en condiciones de iluminación compleja. El modelo supera las limitaciones del algoritmo CrackForest, extrayendo información completa de las grietas. Evaluado en los conjuntos CFD y Cracktree200, alcanzó precisiones de hasta 87.4% y F1-scores superiores al 85%. Es aplicable a detección estructural en entornos ruidosos y con topologías complejas.

Este documento (Farahzadi et al., 2025) ofrece un análisis del panorama actual en la evaluación automática de daños en infraestructuras utilizando procesamiento de imágenes y visión por computadora. Considerando las limitaciones de los métodos de inspección convencionales, se exploran enfoques que involucran redes neuronales convolucionales, máquinas de soporte vectorial y técnicas de clasificación para detectar, identificar y cuantificar los daños. Se reconocen los tipos de daños más frecuentes, así como los requerimientos técnicos necesarios para llevar a cabo su evaluación, subrayando tanto las ventajas como las desventajas de cada técnica. Este estudio sugiere consejos prácticos para elegir estrategias adecuadas según el contexto, con el fin de aumentar la precisión, el alcance y la eficacia en la inspección del entorno construido.

2. MARCO REFERENCIAL

❖ Procesamiento de imágenes

En el procesamiento digital de imágenes aplicado a estructuras de hormigón, se implementaron diversas técnicas orientadas a mejorar la calidad visual y estructural de las imágenes antes de su análisis geométrico (Méndez-Vázquez et al., 2012). Una de las primeras etapas fue la reducción de ruido (denoise), mediante filtros que atenúan interferencias generadas por texturas superficiales, variaciones de iluminación o artefactos del sensor. Esta limpieza permite preservar los bordes relevantes sin distorsionar la forma de las fisuras. Posteriormente, se aplicó la binarización, que transforma la imagen en una representación de dos niveles (generalmente blanco y negro), facilitando la segmentación precisa del objeto de interés respecto al fondo. Además de estas etapas, el código incluyó procesos de ajuste de contraste, normalización de intensidad, y detección de bordes, que permiten resaltar las zonas afectadas y estandarizar las condiciones de entrada para los algoritmos de clasificación. También se utilizó rotación y alineación automática para corregir desviaciones en la orientación de las muestras, y recorte por regiones de interés (ROI) para enfocar el análisis en zonas representativas. Estas técnicas, combinadas de forma secuencial y controlada, garantizan la reproducibilidad del procesamiento y la confiabilidad de los resultados obtenidos en la clasificación supervisada.

❖ Extracción de características.

Histogram of Oriented Gradients (HOG)

El descriptor HOG (Histogram of Oriented Gradients) es una técnica utilizada para representar la forma y estructura de los objetos en una imagen mediante la distribución de las orientaciones de sus bordes. Este método divide la imagen en celdas pequeñas y calcula los gradientes de intensidad en cada una, agrupando las

direcciones predominantes en histogramas locales. En el contexto del análisis de fisuras, HOG permite capturar trazos lineales y patrones de borde que caracterizan las discontinuidades en el concreto, siendo especialmente útil para distinguir entre superficies lisas y aquellas con presencia de grietas.

Local Binary Pattern (LBP)

El descriptor LBP (Local Binary Pattern) es una técnica de análisis de textura que codifica la relación entre un píxel central y sus vecinos inmediatos. Para cada píxel, se compara su intensidad con la de los píxeles circundantes, generando una secuencia binaria que refleja la variación local de la textura. Esta codificación se transforma en un histograma que representa la distribución de patrones texturales en la imagen. En aplicaciones de detección de fisuras, LBP permite identificar irregularidades superficiales, microfisuras y zonas con desgaste, gracias a su sensibilidad a cambios locales en la textura del concreto.

Gray-Level Co-occurrence Matrix (GLCM)

La matriz de coocurrencia de niveles de gris (GLCM) es un descriptor estadístico que analiza la frecuencia con la que pares de píxeles con valores de intensidad específicos ocurren en una imagen, considerando una distancia y dirección determinadas. A partir de esta matriz, se calculan propiedades como el contraste, la correlación, la energía y la homogeneidad, que permiten caracterizar la textura global de la imagen. En el análisis de fisuras, GLCM es útil para diferenciar superficies homogéneas de aquellas con patrones texturales complejos, como grietas ramificadas o zonas erosionadas, aportando información complementaria a los descriptores locales.

❖ Clasificadores

Árbol de Decisión (Decision Tree)

El Árbol de Decisión es un clasificador supervisado que organiza el proceso de toma de decisiones en una estructura jerárquica compuesta por nodos y ramas. Cada nodo representa una condición basada en una característica del conjunto de

datos, y cada rama define el resultado de dicha condición. El modelo divide recursivamente el espacio de características en regiones homogéneas, facilitando la clasificación de nuevas muestras mediante reglas simples y fácilmente interpretables. En este trabajo, el Árbol de Decisión fue configurado con un número limitado de divisiones y sin poda, lo que permitió mantener una estructura compacta y eficiente para la clasificación de fisuras en concreto a partir de descriptores texturales.

Random Forest

Random Forest es un modelo de ensamble que combina múltiples Árboles de Decisión entrenados sobre subconjuntos aleatorios del conjunto de datos. Cada árbol se construye utilizando una técnica de muestreo con reemplazo (bootstrap), y las decisiones finales se obtienen mediante votación entre los árboles individuales. Esta estrategia permite reducir la varianza del modelo y mejorar su capacidad de generalización, especialmente en problemas con ruido o alta dimensionalidad. En el presente estudio, Random Forest fue implementado con tres ciclos de aprendizaje y árboles base de baja complejidad, lo que permitió evaluar su desempeño en la clasificación de fisuras utilizando combinaciones de características texturales. Aunque su estructura es menos interpretable que la del Árbol de Decisión, ofrece mayor robustez frente a variaciones en los datos.

❖ Métricas

Exactitud

La exactitud es una métrica que indica el porcentaje de predicciones correctas realizadas por el modelo sobre el total de muestras evaluadas. Esta medida considera tanto los verdaderos positivos como los verdaderos negativos, proporcionando una visión general del rendimiento del clasificador. En el contexto de detección de fisuras, una alta exactitud sugiere que el modelo logra identificar correctamente tanto las imágenes con daño como aquellas sin discontinuidades.

Sensibilidad

La sensibilidad, también conocida como tasa de verdaderos positivos, mide la capacidad del modelo para detectar correctamente las muestras que pertenecen a la clase positiva. Es especialmente relevante en aplicaciones de inspección estructural, donde omitir una fisura puede tener consecuencias críticas. Un valor elevado de sensibilidad indica que el clasificador tiene buen desempeño en la identificación de imágenes con fisuras o grietas.

Especificidad

La especificidad representa la proporción de verdaderos negativos correctamente identificados por el modelo. Esta métrica evalúa la capacidad del clasificador para reconocer las muestras que no presentan daño. En el análisis de concreto, una alta especificidad garantiza que las superficies sin fisuras no sean clasificadas erróneamente como defectuosas, evitando falsas alarmas en sistemas de monitoreo.

Recall

El recall es una métrica que cuantifica la capacidad del modelo para recuperar correctamente todas las instancias relevantes de la clase positiva. Aunque está estrechamente relacionada con la sensibilidad, el recall se enfoca en la cobertura de detección, es decir, cuántas fisuras reales fueron efectivamente identificadas. Un valor alto de recall indica que el modelo tiene bajo nivel de omisión en la clasificación de discontinuidades.

F1-score

El F1-score es una métrica compuesta que combina la precisión y el recall en una media armónica, ofreciendo un balance entre ambos indicadores. Es especialmente útil cuando se busca evaluar el rendimiento del modelo en escenarios con clases desbalanceadas o cuando se requiere un compromiso entre detección y exactitud. En este estudio, el F1-score permitió comparar de forma integral el desempeño de los clasificadores en distintas combinaciones de características texturales.

3. DISEÑO DE LA INVESTIGACIÓN

Tipo de investigación: El presente trabajo se enmarca dentro de una investigación explicativa, ya que busca identificar y justificar las relaciones causales entre las técnicas de procesamiento de imágenes, los algoritmos de clasificación supervisada (Random Forest y Decision Tree) y su impacto en la detección automática de fisuras y grietas en estructuras de concreto. Asimismo, posee componentes descriptivos, al caracterizar morfológica y texturalmente los patrones de fisuración presentes en las imágenes analizadas.

Enfoque: El enfoque adoptado es cuantitativo, dado que se trabaja con datos numéricos extraídos de imágenes digitales, se aplican algoritmos computacionales y se evalúa el desempeño mediante métricas estadísticas como precisión, exactitud, sensibilidad y matriz de confusión. Este enfoque permite validar objetivamente la eficacia de los modelos propuestos en escenarios simulados y reales.

Método: Se emplea un método analítico-deductivo, partiendo de principios teóricos del procesamiento digital de imágenes y de la clasificación supervisada, para luego aplicar dichos fundamentos en el diseño experimental. El análisis se realiza sobre conjuntos de datos previamente etiquetados, lo que permite deducir el comportamiento de los modelos ante nuevas muestras.

Técnicas: La técnica principal utilizada es el experimento computacional, mediante la simulación de escenarios de inspección estructural. Se procesan imágenes reales de concreto fisurado, se extraen características morfológicas y texturales (HOG, LBP, GLCM), y se aplican algoritmos de clasificación para evaluar su capacidad de discriminación. No se emplean encuestas ni instrumentos de recolección social, dado que el estudio se centra en datos técnicos y visuales.

Diseño experimental: El entorno de trabajo se define como un laboratorio computacional, utilizando software especializado (MATLAB, Python o similares) para el procesamiento de imágenes y la implementación de algoritmos. Las

condiciones experimentales incluyen la estandarización de resolución, iluminación y formato de las imágenes. El muestreo se realiza de forma dirigida, seleccionando imágenes representativas de distintos tipos de fisuras. No se requiere cartografía ni observación directa en campo, dado que el análisis se realiza sobre registros visuales digitalizados.

Procedimiento o fases:

El desarrollo de la investigación se estructura en las siguientes fases:

1. **Selección del conjunto de imágenes:** Se recopilan imágenes de estructuras de concreto con presencia de fisuras y grietas, provenientes de bases de datos públicas o registros propios.
2. **Preprocesamiento de imágenes:** Se aplican técnicas como reducción de ruido, binarización, ajuste de contraste y detección de bordes, con el fin de mejorar la visibilidad de las discontinuidades.
3. **Extracción de características:** Se obtienen atributos texturales (HOG, LBP, GLCM), que permiten representar cuantitativamente las fisuras.
4. **Implementación de algoritmos:** Se entrenan modelos de clasificación supervisada (Random Forest y Decision Tree) sobre los vectores de características extraídos.
5. **Evaluación del desempeño:** Se aplican métricas cuantitativas para comparar la eficacia de los modelos, considerando su capacidad de clasificación en condiciones reales de inspección.
6. **Documentación y análisis:** Se sistematizan los resultados obtenidos, se interpretan los hallazgos y se proponen recomendaciones para futuras aplicaciones en sistemas automatizados de monitoreo estructural.

4. DESARROLLO DEL TRABAJO DE GRADO

Para el desarrollo del trabajo se realizó en fases que se nombraron en el diseño de la investigación, como primer paso se reviso la base de datos en donde se encontraron las imágenes desbalanceadas es decir 86 para fisuras y 24 para grietas, en la figura # se observa la imagen original de la para la fisura y grieta.

Figura 1. Imágenes base de datos.

Fisura - Original



Grieta - Original




Fuente: Autor.

En la fase dos se realizó el procesamiento de las imágenes. Durante esta fase, se implementó una función (funtion) computacional en MATLAB con el objetivo de mejorar la visibilidad y segmentación en las imágenes. El procedimiento inicia con la lectura de la imagen original y su conversión a escala de grises en caso de contener tres canales de color. Posteriormente, se aplica una ecualización adaptativa del histograma (adaphisteq) para realzar los contrastes locales, seguida de un filtrado de mediana (medfilt2) con una ventana de 3×3, lo cual permite reducir el ruido impulsivo sin afectar los bordes relevantes. La binarización se realiza mediante un umbral adaptativo con polaridad oscura (imbinarize), lo que facilita la separación de las fisuras respecto al fondo.

A continuación, se aplican dos operaciones morfológicas de cierre (imclose) utilizando elementos estructurantes lineales en direcciones horizontal y vertical, con el fin de mejorar la conectividad de los trazos y eliminar discontinuidades espurias. Finalmente, se ejecuta una operación de limpieza (bwareaopen) para eliminar objetos pequeños no representativos, conservando únicamente las regiones de interés asociadas a discontinuidades significativas. Este flujo de procesamiento garantiza una segmentación robusta, homogénea y reproducible, optimizando las condiciones para la posterior extracción de características morfológicas y texturales. En la figura # se observa este proceso anterior mete descrito.

Figura 2. Imágenes Procesadas.

Fisura - Contraste Denoise Grieta - Contraste Denoise



Fisura - Binarizado



Grieta - Binarizado



Fisura - Post-morfología



Grieta - Post-morfología



Fuente: Autor.

Durante la etapa de extracción de características, se emplearon tres descriptores texturales ampliamente utilizados en el análisis de imágenes técnicas:

HOG, LBP y GLCM. El descriptor Histogram of Oriented Gradients (HOG) permite capturar la distribución de las orientaciones de los bordes presentes en la imagen. Para ello, se aplicó la función (`extractHOGFeatures`) sobre la imagen preprocesada, utilizando una celda de tamaño definido (`hogCellSize`). Este procedimiento genera un vector que representa la intensidad y dirección de los gradientes locales, facilitando la identificación de patrones lineales como fisuras.


El segundo descriptor utilizado fue el Local Binary Pattern (LBP), el cual codifica la textura local de cada píxel comparando su intensidad con la de sus vecinos. La función (`extractLBPFeatures`) fue aplicada con una celda de tamaño específico (`lbpCellSize`), generando un vector que refleja la variación de texturas en la imagen. Este descriptor es especialmente útil para detectar irregularidades superficiales y microfisuras en el concreto.

Finalmente, se empleó la Matriz de Coocurrencia de Niveles de Gris (GLCM) para capturar relaciones espaciales entre píxeles. Se generó la matriz mediante la función (`graycomatrix`), considerando un desplazamiento horizontal de un píxel (`Offset = [0 1]`). A partir de esta matriz, se calcularon cuatro propiedades estadísticas mediante `graycoprops`: contraste, correlación, energía y homogeneidad, las cuales fueron agrupadas en un vector (`featsGLCM`). Estas métricas permiten cuantificar la textura global de la imagen, diferenciando superficies lisas de aquellas con presencia de fisuras o grietas.

Para la etapa de clasificación supervisada se implementaron dos modelos ampliamente utilizados en problemas de reconocimiento de patrones: Árbol de Decisión y Random Forest. El Árbol de Decisión fue construido mediante la función (`fitctree`), configurando un tamaño mínimo de hoja de 5 (`MinLeafSize = 5`) y un número máximo de divisiones igual a 10 (`MaxNumSplits = 10`), sin aplicar poda posterior (`Prune = 'off'`). Este clasificador genera una estructura jerárquica que divide recursivamente el espacio de características en función de umbrales óptimos, permitiendo una interpretación clara de las reglas de decisión. Por su parte, el


modelo Random Forest fue implementado como un ensamble de árboles de decisión utilizando la función `fitcensemble` con el método de agregación por bootstrap (Method = 'Bag'). Se configuraron tres ciclos de aprendizaje (NumLearningCycles = 3), cada uno entrenado sobre subconjuntos aleatorios de los datos, y se utilizó como aprendiz base un árbol con un máximo de tres divisiones (MaxNumSplits = 3) y hojas mínimas de tamaño 5 (MinLeafSize = 5). En la implementación de los clasificadores los datos se ingresaron balanceados, este balance permitió que los modelos aprendieran de manera uniforme las características de cada categoría, mejorando su capacidad de generalización y reduciendo el riesgo de sobreajuste hacia clase mayoritarias en nuestro caso las fisuras que son 84 vs las 24 de grietas. A continuación, se evidencia figura 3 a 8 la implementación de cada una de las combinaciones de las características, HOG vs LBP, HOG vs GLCM, LBP vs GLCM.

Figura 3. Decision Tree HOG vs LBP.




Fuente: Autor.

Figura 4. Random Forest HOG vs LBP.




Fuente: Autor.

Figura 5. Decision Tree HOG vs GLCM.




Fuente: Autor.

Figura 6. Random Forest HOG vs GLCM.




Fuente: Autor.

Figura 7. Decision Tree LBP vs GLCM.



Fuente: Autor.

Figura 8. Random Forest LBP vs GLCM.



Fuente: Autor.

5. RESULTADOS

Para evaluar el desempeño de los clasificadores implementados, se utilizaron cinco métricas estándar en problemas de clasificación supervisada: exactitud, sensibilidad, especificidad, recuperación (recall) y F1-score. La exactitud mide el porcentaje de predicciones correctas sobre el total de muestras; la sensibilidad indica la capacidad del modelo para detectar correctamente las clases positivas; la especificidad refleja su habilidad para identificar correctamente las clases negativas; el recall representa la proporción de verdaderos positivos sobre los casos relevantes; y el F1-score combina precisión y recall en una sola métrica armónica.

Los resultados muestran que el clasificador **Árbol de Decisión (DT)** obtuvo un mejor desempeño general en comparación con **Random Forest (RF)** en la mayoría de combinaciones de características. En particular, la combinación **HOG vs LBP** con DT alcanzó la mayor exactitud (0.875) y un F1-score de 0.88, evidenciando una alta capacidad de discriminación entre clases. Por otro lado, RF con la misma combinación presentó una exactitud de 0.6875 y un F1-score de 0.7058, lo que indica una menor estabilidad en la clasificación.

Tabla 1. Métricas de los diferentes clasificadores.

Características	Modelo	Exactitud	Sensibilidad	Especificidad	Recall	F1
HOG_vs_LBP	DT	0.875	0.8461	0.8333	0.9166	0.88
HOG_vs_LBP	RF	0.6875	0.6666	0.625	0.75	0.7058
HOG_vs_GLCM	DT	0.8125	0.7777	0.75	0.875	0.8235
HOG_vs_GLCM	RF	0.625	0.6875	0.7916	0.4583	0.55

LBP_vs_GLCM	DT	0.8333	0.7857	0.75	0.9166	0.8461
LBP_vs_GLCM	RF	0.7916	0.7058	0.5833	1	0.8275

Fuente: Autor

En el caso de **HOG vs GLCM**, DT mantuvo un rendimiento aceptable (exactitud de 0.8125 y F1-score de 0.8235), mientras que RF mostró una caída significativa en el recall (0.4583) y en el F1-score (0.55), lo que sugiere dificultades para identificar correctamente las clases positivas. Finalmente, la combinación **LBP vs GLCM** con DT logró una exactitud de 0.8333 y un F1-score de 0.8461, mientras que RF alcanzó su mejor desempeño relativo en esta configuración, con un F1-score de 0.8275 y un recall perfecto (1), aunque con menor especificidad (0.5833). Estos resultados evidencian que el Árbol de Decisión ofrece mayor consistencia y equilibrio entre métricas, especialmente en conjuntos de datos balanceados y con características texturales bien definidas.

6. CONCLUSIONES

1. La integración de técnicas de preprocesamiento de imágenes con descriptores texturales (HOG, LBP, GLCM) y clasificadores supervisados como Árbol de Decisión y Random Forest permitió desarrollar un modelo eficiente para la detección automática de fisuras en concreto, adaptado a condiciones operativas del entorno urbano colombiano.
2. Los resultados obtenidos evidencian que el Árbol de Decisión presenta un desempeño más estable y equilibrado en términos de exactitud, sensibilidad y F1-score, especialmente cuando se utilizan combinaciones de características como HOG vs LBP y LBP vs GLCM, lo que lo convierte en una alternativa viable para aplicaciones con recursos computacionales limitados.
3. El uso de un conjunto de datos balanceado y la selección adecuada de características texturales contribuyeron significativamente a mejorar la capacidad de generalización de los modelos, demostrando que es posible implementar soluciones automatizadas de inspección estructural con alta precisión, bajo costo computacional y potencial de escalabilidad en contextos reales.

7. REFERENCIAS BIBLIOGRÁFICAS

- Chun, P., Ujike, I., Mishima, K., Kusumoto, M., & Okazaki, S. (2020). Random forest-based evaluation technique for internal damage in reinforced concrete featuring multiple nondestructive testing results. *Construction and Building Materials*, 253, 119238.
- Espillco Quintanilla, F. W. (2024). *Determinación de fisuras y grietas en estructuras de concreto mediante el procesamiento de imágenes utilizando un modelo de redes neuronales artificiales en la provincia de Huamanga, 2024*.
- Farahzadi, L., Odeh, I., Kioumars, M., & Shafei, B. (2025). Automated Image-Based Condition Assessment of Built Environment: A State-of-the-Art Investigation of Damage Characteristics and Detection Requirements. *Results in Engineering*, 104978.
- Flah, M., Suleiman, A. R., & Nehdi, M. L. (2020). Classification and quantification of cracks in concrete structures using deep learning image-based techniques. *Cement and Concrete Composites*, 114, 103781.
- Frias, D., & Hidalgo, J. (2021). *A high accuracy image hashing and random forest classifier for crack detection in concrete surface images*.
- Islam, M. M., Hossain, M. B., Akhtar, M. N., Moni, M. A., & Hasan, K. F. (2022). CNN based on transfer learning models using data augmentation and transformation for detection of concrete crack. *Algorithms*, 15(8), 287.
- Kim, H., Ahn, E., Shin, M., & Sim, S.-H. (2019). Crack and noncrack classification from concrete surface images using machine learning. *Structural Health Monitoring*, 18(3), 725–738.
- Kyal, C., Reza, M., Varu, B., & Shreya, S. (2021). Image-based concrete crack detection using random forest and convolution neural network. In *Computational Intelligence in Pattern Recognition: Proceedings of CIPR 2021* (pp. 471–481). Springer.
- Lozano, F. J. R. (2020). *Sistema automático para la detección y clasificación de grietas en pavimentos*. Universidad de Córdoba (ESP).
- Marín-Acevedo, E. A. (2020). *Detección automática de grietas y fisuras en pavimento por medio de fotos y redes neuronales convolucionales*.
- Méndez-Vázquez, H., Chang, L., Rizo-Rodríguez, D., & Morales-González, A. (2012). Evaluación de la calidad de las imágenes de rostros utilizadas para la identificación de las personas. *Computación y Sistemas*, 16(2), 147–165.
- Rashid, T., & Mokji, M. M. (2022). Low-resolution image classification of cracked concrete surface using decision tree technique. In *Control, Instrumentation and Mechatronics: Theory and Practice* (pp. 641–649). Springer.
- Wang, X., Wang, X., Li, J., Liang, W., & Bi, C. (2024). Research on Pavement Crack Detection Based on Random Structure Forest and Density Clustering. *Automation*, 5(4), 467–483.
- Wu, L., Lin, X., Chen, Z., Lin, P., & Cheng, S. (2021). Surface crack detection based on image stitching and transfer learning with pretrained convolutional neural network. *Structural Control and Health Monitoring*, 28(8), e2766.
- Zhu, J., & Song, J. (2020). An intelligent classification model for surface defects on cement concrete bridges. *Applied Sciences*, 10(3), 972.
- Zoubir, H., Rguig, M., El Aroussi, M., Chehri, A., & Saadane, R. (2022). Concrete bridge crack image classification using histograms of oriented gradients, uniform local binary

F-DC-125

INFORME FINAL DE TRABAJO DE GRADO EN MODALIDAD DE
PROYECTO DE INVESTIGACIÓN, DESARROLLO TECNOLÓGICO,
MONOGRAFÍA, EMPRENDIMIENTO Y SEMINARIO

VERSIÓN: 2.0

patterns, and kernel principal component analysis. *Electronics*, 11(20), 3357.