

**HERRAMIENTA DE *SOFTWARE* PARA EL RECONOCIMIENTO  
DE FALLAS TIPO DESPRENDIMIENTOS  
EN PAVIMENTO FLEXIBLE**

**MIGUEL ÁNGEL ALARCÓN SANABRIA**

**JAHIR AUGUSTO SAAVEDRA GARCÍA**

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

**2014**

**HERRAMIENTA DE *SOFTWARE* PARA EL RECONOCIMIENTO  
DE FALLAS TIPO DESPRENDIMIENTOS  
EN PAVIMENTO FLEXIBLE**

**MIGUEL ÁNGEL ALARCÓN SANABRIA  
JAHIR AUGUSTO SAAVEDRA GARCÍA**

**TRABAJO DE GRADO PARA OPTAR EL TÍTULO DE INGENIERO DE  
SISTEMAS**

**DIRECTOR  
HERNÁN PORRAS DÍAZ  
Ingeniero Civil, PhD.**

**CODIRECTOR  
DUVÁN YAHÍR SANABRIA ECHEVERRY  
Ingeniero de Sistemas, MSc.**

**UNIVERSIDAD INDUSTRIAL DE SANTANDER  
FACULTAD DE INGENIERÍAS FISICOMECAÑICAS  
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA  
BUCARAMANGA  
2014**

## DEDICATORIA

A Dios, porque sin su ayuda no hubiera conseguido alcanzar este logro.

A mi mamá María I y mi papá Julio Roberto por su apoyo irrestricto, sus consejos, por la motivación en la consecución de esta meta y por creer en mí.

A mis hermanos Julio Andrés y Juan David por sus buenos deseos y apoyo.

A mis amigos por sus aportes y enseñanzas.

*Miguel Ángel Alarcón Sanabria*

## **AGRADECIMIENTOS**

A Dios por darme la capacidad, la inteligencia, y todas las demás virtudes necesarias para la consecución de este logro.

Al profesor Hernán Porras Díaz director de este proyecto de grado por el tiempo dedicado, por su aporte, apoyo, respaldo y confianza.

Al Ingeniero de Sistemas, magíster Duván Yahír Sanabria Echeverry codirector de este proyecto por su orientación, por su aporte con su conocimiento, y su interese.

Al profesor Eduardo Alberto Castañeda Pinzón por su asesoría en el tema de pavimentos a lo largo del trabajo de investigación.

A mi compañero de proyecto de grado por su colaboración y contribución en el desarrollo de este trabajo de investigación.

A la Escuela de Ingeniería de Sistemas e Informática por la formación académica recibida.

Al grupo de investigación Geomática, gestión y optimización de sistemas por brindarme su confianza, apoyo material y humano en el desarrollo de este trabajo de investigación.

A la Universidad Industrial de Santander por su apoyo con recursos a través de sus distintas unidades académicas, administrativas, y de bienestar contribuyendo directa o indirectamente al desarrollo de este trabajo de investigación.

A mi familia por su apoyo moral y material para la conquista de esta meta.

*Miguel Ángel Alarcón Sanabria*

# *Dedicatoria & Agradecimientos*

*Al culminar la escritura plasmada  
una reflexión indaga mis pensamientos  
se centra en este documento  
cuyo texto tan solo refleja  
una aproximación de todo un cuento.*

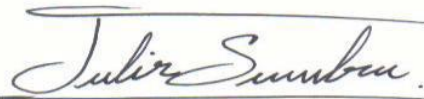
*Y no es que merezca más ni menos texto  
ni que se salga de contexto  
tan solo son acontecimientos  
que llevaron a culminar este documento.*

*Que no se olviden las madrugadas, traspasos,  
reuniones y búsqueda de varios elementos  
donde entidades y personas como el Dr. Hernán  
Duván, Nelson, Diego, Paola, Viviana y Jeison  
aportaron para este gran acontecimiento.*

*Me disculpan quienes no haya nombrado  
pero esto de versear limita mucho el texto  
tengan en cuenta que siempre estarán  
en una que otra salida fuera de contexto.*

*A memoria de mi familia por su apoyo incondicional: Aura  
Esther, Marco A., Tatiana, Marco F. (q.e.p.d.), Diana,  
Michell, Sofía y Alejandro.*

*Cordialmente,*



*Jahir Augusto Saavedra García*

## CONTENIDO

INTRODUCCIÓN .....	25
1. OBJETIVOS .....	27
1.1 OBJETIVO GENERAL .....	27
1.2 OBJETIVOS ESPECÍFICOS.....	27
2. JUSTIFICACIÓN .....	28
2.1 DEFINICIÓN DEL PROBLEMA .....	28
2.2 IMPACTO ESPERADO.....	28
2.3 VIABILIDAD .....	29
2.4 ESTADO DEL ARTE.....	29
3. MARCO TEÓRICO .....	31
3.1 PAVIMENTO.....	31
3.2 PAVIMENTO FLEXIBLE .....	32
3.2.1 Capas del Pavimento Flexible .....	32
3.2.2 Materiales Utilizados en las Capas de Pavimento Flexible .....	35
3.3 FALLAS TIPO DESPRENDIMIENTOS EN PAVIMENTO FLEXIBLE .....	36
3.3.1 Cabeza Duras .....	36
3.3.2 Descascaramiento:.....	37
3.3.3 Baches: .....	39
3.4 TRATAMIENTO DIGITAL DE IMÁGENES .....	40
4. METODOLOGÍA DE IMPLEMENTACIÓN .....	43
5. ADQUISICIÓN DE IMÁGENES.....	47
5.1 PRIMER MODELO DE ADQUISICIÓN.....	47
5.2 SEGUNDO MODELO DE ADQUISICIÓN.....	48
5.3 TERCER MODELO DE ADQUISICIÓN .....	50
5.3.1 Imágenes de falla tipo cabezas duras .....	51
5.3.2 Imágenes de falla tipo descascaramiento .....	51
5.3.3 Imágenes de falla tipo bache .....	51
6. PREPROCESAMIENTO .....	52
6.1 CARACTERIZACIÓN DE LAS FALLAS TIPO DESPRENDIMIENTO EN PAVIMENTO FLEXIBLE .....	52
6.2 HISTOGRAMA DE LAS IMÁGENES A ESCALA DE GRISES .....	54

6.3	ACONDICIONAMIENTO DE LAS IMÁGENES CON FALLAS TIPO DESCASCARAMIENTO Y BACHE ( <i>POTHOLE</i> O HUECOS) .....	55
6.3.1	Suavizado de la imagen .....	55
6.3.2	Contraste de la imagen .....	56
6.3.3	Corrección de iluminación (homogeneización) de la imagen [18] .....	56
6.4	ACONDICIONAMIENTO DE LAS IMÁGENES CON FALLAS TIPO CABEZAS DURAS.....	58
7.	SEGMENTACIÓN .....	60
7.1	PROCESO DE SEGMENTACIÓN PARA LAS FALLAS DE TIPO DESCASCARAMIENTO Y BACHE ( <i>POTHOLE</i> O HUECOS) .....	60
7.1.1	Contorno Activo.....	60
7.1.2	Eliminación de ruido pos-segmentación.....	64
7.2	PROCESO DE SEGMENTACIÓN PARA LAS FALLAS DE TIPO CABEZAS DURAS .....	69
7.2.1	Umbralización .....	69
7.2.2	Algoritmo de segmentación.....	69
7.3	COMBINACIÓN ALGORITMOS DE SEGMENTACIÓN.....	71
8.	DESCRIPCIÓN .....	73
8.1	CARACTERÍSTICAS INTERNAS.....	73
8.1.1	Escalaes simples .....	73
8.1.2	Textura .....	74
8.2	MÉTODO ESTADÍSTICO DE TEXTURA.....	75
8.3	ESTADÍSTICOS DE PRIMER ORDEN.....	75
8.4	ESTADÍSTICOS DE SEGUNDO ORDEN.....	76
8.4.1	Cálculo de estadísticos de segundo orden.....	78
9.	CLASIFICACIÓN.....	82
9.1	VECTOR DE CARACTERÍSTICAS .....	82
9.2	SELECCIÓN DE DESCRIPTORES RELEVANTES .....	82
9.2.1	Selección de características:.....	83
9.3	CLASIFICADOR .....	93
10.	ANÁLISIS DE RESULTADOS.....	97
10.1	PRUEBAS DE DETECCIÓN.....	97
10.2	PRUEBAS DE CLASIFICACIÓN .....	99
10.2.1	Métricas de rendimiento.....	99

10.2.2 Validación .....	100
10.2.3 Resultados .....	101
10.3 TIEMPO PROMEDIO DE EJECUCIÓN DE LOS ALGORITMOS .....	102
11. CONCLUSIONES .....	103
12. RECOMENDACIONES .....	104
CITAS BIBLIOGRÁFICAS.....	105
BIBLIOGRAFÍA.....	109
ANEXOS.....	112

## LISTA DE FIGURAS

<b>Figura 1.</b> Estructura de pavimento flexible [10] .....	32
<b>Figura 2.</b> Algunos materiales utilizados en el diseño de pavimentos [10] .....	35
<b>Figura 3.</b> Desprendimiento tipo cabeza dura [12].....	37
<b>Figura 4:</b> Descascaramiento [12] .....	38
<b>Figura 5.</b> Baches [12].....	39
<b>Figura 6.</b> Etapas procesamiento digital de imágenes [14].....	41
<b>Figura 7.</b> Diagrama de casos de uso .....	43
<b>Figura 8.</b> Diagrama del modelo de análisis .....	44
<b>Figura 9.</b> Diagrama diseño de la integración de algoritmos .....	44
<b>Figura 10.</b> Diseño rápido interfaz usuario .....	45
<b>Figura 11.</b> Prototipo herramienta <i>software</i> .....	45
<b>Figura 12.</b> Imágenes de muestras de línea láser, primer modelo de adquisición..	47
<b>Figura 13.</b> Pruebas del prototipo <i>software</i> .....	48
<b>Figura 14.</b> Montaje segundo modelo de adquisición .....	49
<b>Figura 15.</b> Imágenes segundo modelo de adquisición .....	49
<b>Figura 16.</b> Tercer modelo de adquisición .....	50
<b>Figura 17.</b> Diagrama del proceso propuesto .....	53
<b>Figura 18.</b> Fallas de tipo desprendimiento con su respectivo histograma .....	54
<b>Figura 19.</b> Filtro mediana y tendencia general del histograma.....	55
<b>Figura 20.</b> Ajuste de contraste de la imagen .....	56
<b>Figura 21.</b> Corrección de iluminación de la imagen y su respectivo histograma ...	58
<b>Figura 22.</b> Falla tipo cabezas duras con filtro mediana y su respectivo histograma .....	59
<b>Figura 23.</b> Falla tipo cabezas duras con ecualización adaptativa .....	59
<b>Figura 24.</b> Representación gráfica del método Chan-Vese.....	62
<b>Figura 25.</b> Imagen reducción de tamaño de 94%.....	62
<b>Figura 26.</b> Snake, Máscara o Curva Inicial .....	63
<b>Figura 27.</b> Resultado de aplicar segmentación por contorno activo .....	63
<b>Figura 28.</b> Selección y eliminación de regiones menores o iguales a 100 píxeles	64
<b>Figura 29.</b> Redimensión de la imagen a tamaño de 3456 x 4608 píxeles .....	64
<b>Figura 30.</b> Evaluación de Solidez $\leq 0,42$ .....	65
<b>Figura 31.</b> Resultado Solidez $\leq 0,42$ .....	65
<b>Figura 32.</b> Borde demarcado por una región abierta.....	66
<b>Figura 33.</b> Cerrar región con puntos extremos.....	66
<b>Figura 34.</b> Verificación de regiones.....	67
<b>Figura 35.</b> $RegQ$ calculado para evaluar regiones.....	68
<b>Figura 36.</b> Resultado de la verificación de regiones con $RegQ \geq 40$ .....	68
<b>Figura 37.</b> Resultado segmentación algoritmo Cabezas Duras .....	70
<b>Figura 38.</b> Combinación algoritmos de segmentación .....	72
<b>Figura 39.</b> Tres diferentes matrices de coocurrencia para una imagen 4x4 I en tono de grises: $C_{0,1}$ , $C_{1,0}$ , $C(1,1)$ [31]. .....	76
<b>Figura 40.</b> Relación dirección y distancia, píxel de interés y su vecindad [27]. ....	78
<b>Figura 41.</b> Algoritmo de bloqueo [33] .....	79

<b>Figura 42.</b> Construcción de matriz de coocurrencia para $d=1$ : Imagen original (caso base) (a) empieza por examinar cada uno de sus pares de vecinos: Parte (b) muestra la etapa incremental que ocurre cuando los píxeles vecinos esbozados en (a) son examinados. Parte(c) muestra el resultado final de la matriz de coocurrencia para $d=1$ [33].	80
<b>Figura 43.</b> Esta es una ilustración del paso recursivo de comparación de niños. Parte (a) Muestra el padre de un niño oscuro(c). Este niño de (a) se utilizará para calcular coocurrencias con cada uno de los niños oscuros mostrados en la parte (b). Parte (d) es un niño en particular de (b) que es para ser comparado con (c). Parte (c) y (d) entonces repiten este proceso hasta que el caso base se ha alcanzado [33].	80
<b>Figura 44.</b> La parte (a) muestra todos los hermanos que deben ser comparados en el caso de 135 grados. Parte (b) muestra los hermanos que deben ser comparados en el caso de 90 grados. Parte (c) muestra los hermanos que deben ser comparados en el caso de 45 grados. Parte (d) muestra los hermanos que deben ser comparados en el caso de 0 grados [33].	81
<b>Figura 45.</b> Gráfica de los patrones empleando el subconjunto óptimo seleccionado de características.	93
<b>Figura 46.</b> Esquema general de la solución	93
<b>Figura 47.</b> Representación gráfica del modelo de optimización a resolver [37].	95
<b>Figura 48.</b> Ejemplo clasificación de fallas (a) clasificación entre cabezas duras y pothole (b) clasificación entre descascaramiento y bache (c) imagen combinada de los resultados del clasificador 1 y el clasificador 2.	96
<b>Figura 49.</b> Ilustración método de validación cruzada: Validación cruzada de K iteraciones con $K=4$ .	100
<b>Figura 50.</b> Diagrama de flujo de la herramienta software	115
<b>Figura 51.</b> Inicio de sesión de la herramienta <i>software</i>	116
<b>Figura 52.</b> Primera interfaz de usuario iniciada la herramienta software	117
<b>Figura 53.</b> Abrir directorio de imágenes o única imagen	118
<b>Figura 54.</b> Ejecución única imagen	119
<b>Figura 55.</b> Resultado procesamiento única imagen seleccionada.	120

## LISTA DE TABLAS

<b>Tabla 1.</b> Tamaños de tamiz para la selección del material granular [10].....	36
<b>Tabla 2.</b> Nivel de severidad de los baches [10] .....	40
<b>Tabla 3.</b> Operador lógico “AND” del álgebra booleana.....	71
<b>Tabla 4.</b> Operador lógico “OR” del álgebra booleana .....	71
<b>Tabla 5.</b> Valores de estructura para d=1 .....	78
<b>Tabla 6.</b> Valores de estructura para d=2 .....	78
<b>Tabla 7.</b> Métodos de selección de subconjuntos [41]......	85
<b>Tabla 8.</b> Clasificación por valor FDR para el primer <i>dataset</i> (integrado por los patrones de la clase cabezas duras y la clase <i>pothole</i> ).....	86
<b>Tabla 9.</b> Clasificación por valor FDR para el segundo <i>dataset</i> (integrado por los patrones de la clase bache y la clase descascaramiento) .....	87
<b>Tabla 10.</b> Clasificación por valor FDR y teniendo en cuenta correlación cruzada para el primer <i>dataset</i> . .....	89
<b>Tabla 11.</b> Clasificación por valor FDR y teniendo en cuenta correlación cruzada para el segundo <i>dataset</i> .....	90
<b>Tabla 12.</b> Características de las mejores clasificadas en el primer <i>dataset</i> tenidas en cuenta para la búsqueda exhaustiva. ....	91
<b>Tabla 13.</b> Características de las mejores clasificadas en el segundo <i>dataset</i> tenidas en cuenta para la búsqueda exhaustiva. ....	91
<b>Tabla 14.</b> Subconjunto óptimo seleccionado de características para el primer <i>dataset</i> .....	92
<b>Tabla 15.</b> Subconjunto óptimo seleccionado de características para el segundo <i>dataset</i> .....	92
<b>Tabla 16.</b> Descripción y resultados de los indicadores utilizados para sensibilidad y especificidad .....	98
<b>Tabla 17.</b> Resultados sensibilidad y especificidad.....	98
<b>Tabla 18.</b> Resultados tiempo promedio en segundos de los algoritmos implementados.....	102
<b>Tabla 19.</b> Tabla función <i>kernel</i> lineal clasificador 1 .....	121
<b>Tabla 20.</b> Tabla función <i>kernel</i> cuadrático clasificador 1 .....	121
<b>Tabla 21.</b> Tabla sensibilidad para función <i>kernel</i> polinomial clasificador 1.....	122
<b>Tabla 22.</b> Tabla especificidad para función <i>kernel</i> polinomial clasificador 1.....	122
<b>Tabla 23.</b> Tabla PPV para función <i>kernel</i> polinomial clasificador 1 .....	122
<b>Tabla 24.</b> Tabla NPV para función <i>kernel</i> polinomial clasificador 1 .....	123
<b>Tabla 25.</b> Tabla CCM para función <i>kernel</i> polinomial clasificador 1 .....	123
<b>Tabla 26.</b> Tabla sensibilidad para función <i>kernel</i> base radial gaussiano clasificador 1.....	123
<b>Tabla 27.</b> Tabla de especificidad para función <i>kernel</i> base radial gaussiano clasificador 1 .....	124
<b>Tabla 28.</b> Tabla PPV para función <i>kernel</i> base radial gaussiano clasificador 1 ..	124
<b>Tabla 29.</b> Tabla NPV para función <i>kernel</i> base radial gaussiano clasificador 1 ..	125

<b>Tabla 30.</b>	Tabla CCM para función <i>kernel</i> base radial gaussiano clasificador 1	.125
<b>Tabla 31.</b>	Tabla función <i>kernel</i> lineal clasificador 2	.....126
<b>Tabla 32.</b>	Tabla función <i>kernel</i> cuadrático clasificador 2	.....126
<b>Tabla 33.</b>	Tabla Sensibilidad para función <i>kernel</i> polinomial clasificador 2	.....127
<b>Tabla 34.</b>	Tabla especificidad para función <i>kernel</i> polinomial clasificador 2	.....127
<b>Tabla 35.</b>	Tabla PPV para función <i>kernel</i> polinomial clasificador 2	.....127
<b>Tabla 36.</b>	Tabla NPV para función <i>kernel</i> polinomial clasificador 2	.....128
<b>Tabla 37.</b>	Tabla CCM para función <i>kernel</i> polinomial clasificador 2	.....128
<b>Tabla 38.</b>	Tabla sensibilidad para función <i>kernel</i> base radial gaussiano	.....128
<b>Tabla 39.</b>	Tabla de especificidad para función <i>kernel</i> base radial gaussiano	.....129
<b>Tabla 40.</b>	Tabla PPV para función <i>kernel</i> base radial gaussiano clasificador 2	..129
<b>Tabla 41.</b>	Tabla NPV para función <i>kernel</i> base radial gaussiano clasificador 2	..130
<b>Tabla 42.</b>	Tabla CCM para función <i>kernel</i> base radial gaussiano clasificador 2	.130

## GLOSARIO

**Acción abrasiva:** Desgaste por fricción que sufre un material.

**Agregado:** Material granular duro e inerte, como la arena, la grava, la escoria o la roca triturada, usado para ser mezclado en diferentes tamaños.

**Algoritmo:** Conjunto de instrucciones o de pasos a seguir para la resolución de un problema específico.

**Algoritmo genético:** Un algoritmo basado en un proceso de tipo “evolutivo que busca una solución final semi-óptima a partir de una población inicial de soluciones candidatas. La población de soluciones candidatas “evoluciona” de una “generación” a otra, usando un criterio de selección de los nuevos individuos.

**Asfalto:** Material ligante, de color oscuro, cuya consistencia decrece notablemente al ser calentado, el cual está constituido predominantemente por betunes, que aparece en la naturaleza o se obtiene por la destilación de crudos de petróleo.

**Bache:** Nombre que dan algunas organizaciones viales a una falla de pavimentos asfálticos también llamada “ojo de pescado”, en tanto que otras se lo asignan a la falla denominada “depresión”.

**Base:** Capa de pavimento construida bajo la capa de rodadura, que transmite a las capas subyacentes, convenientemente disipados, los esfuerzos producidos por las cargas del tránsito. Compromete a las capas que componen el pavimento.

**Betún:** Mezcla de hidrocarburos de origen natural o pirogénico, o de ambos tipos, generalmente acompañados de sus derivados no metálicos. Se caracteriza por ser totalmente soluble en sulfuro de carbono, alto peso molecular, baja tensión de vapor y elevada consistencia a temperatura ambiente. 2. En algunos lugares se da este nombre al asfalto.

**Bitumen:** V. Betún.

**Cabezas duras:** Partículas que sobresalen apreciablemente de la superficie de la capa de rodadura de un pavimento asfáltico o de un afirmado.

**Capa asfáltica:** Capa de pavimento construida con una mezcla asfáltica.

**Capa de rodadura:** Capa superior de un pavimento en contacto directo con el tránsito.

**Capa granular:** Capa construida con escoria triturada, roca triturada, grava y arena trituradas o sin triturar, o cualquier combinación de estos materiales.

**Capacidad de soporte:** Capacidad de un material que forma parte de la fundación de un pavimento, para resistir los esfuerzos que le son transmitidos.

**Capilaridad:** Movimiento de agua a través de los vacíos un suelo, por fuerzas de tensión superficial.

**Característica:** En reconocimiento de patrones, un atributo de un patrón que puede contribuir a la clasificación de patrones; por ejemplo, tamaño, textura, o forma.

**Caracterizar:** Extracción de características de un objeto en la imagen, de modo que se distinga de los demás.

**Carpeta:** Capa de rodadura constituida por una mezcla asfáltica.

**Clase de patrón:** Uno de un conjunto de categorías mutuamente exclusivas en la que un patrón puede ser clasificado.

**Clasificador:** Algoritmo utilizado en clasificación de patrones para asignar una unidad observada de datos de imagen a una clase de patrón basado en características extraídas de la imagen.

**Compactación:** Proceso mecánico mediante el cual se reduce el volumen de un material dado, debido a la salida de parte del aire que ocupa sus vacíos.

**Contraste:** Diferencia en la intensidad en un punto de la imagen y su vecindad.

**Deformación:** Cambio de la geometría de un material o una estructura por la aplicación de un esfuerzo mecánico.

**Descascaramiento:** Pérdida de fragmentos de la capa de rodadura de un pavimento asfáltico, sin afectar las capas inferiores de la estructura.

**Desprendimiento:** Pérdida de material superficial que generalmente afecta pequeñas áreas de un pavimento.

**Distribución granulométrica:** V. Granulometría.

**Dosificar:** Graduar, de la manera más práctica y económica, las proporciones en que se deben incorporar los elementos constitutivos de una mezcla.

**Drenaje:** Acción y efecto de avenar una obra o terreno. 2. Capacidad de la sección estructural del pavimento para evacuar las aguas superficiales y subterráneas que puedan afectar su comportamiento. 3. Medios naturales o artificiales destinados a interceptar y remover las aguas superficiales y subterráneas.

**Entropía:** Es una medida de la complejidad de la imagen. A mayor entropía mayor complejidad.

**Envejecimiento:** Proceso físico químico, debido principalmente a la oxidación, que altera la composición química y la estructura coloidal de un ligante y que en la práctica se manifiesta por el endurecimiento y pérdida de sus características mecánicas y aglomerantes.

**Escoria:** Residuo esponjoso, mayor que la ceniza, que queda tras la combustión del carbón.

**Escoria de alto horno:** Producto no metálico, compuesto principalmente por silicatos y aluminosilicatos de calcio y otras bases, que se obtiene en un alto horno simultáneamente con la producción del hierro.

**Esfuerzo cortante:** Intensidad de la fuerza interna (fuerza por unidad de área) ejercida por una de dos partes adyacentes de un cuerpo sobre la otra a través de un plano imaginario de separación, donde las fuerzas son paralelas al plano.

**Estabilización:** Tratamiento que se da a un suelo por distintas técnicas, con el fin de obtener unas propiedades determinadas, principalmente capacitarlo para soportar adecuadamente la acción del agua y los esfuerzos generados por las cargas del tránsito.

**Filtro:** Transformación de una señal (función de una o varias variables independientes) de entrada mediante una función de transferencia para obtener una señal de salida.

**Fisura:** Línea de rotura de un pavimento, caracterizada por una abertura no mayor de 3 mm.

**Fraguado:** Proceso exotérmico en el cual la pasta acuosa de un conglomerante adquiere trabazón y consistencia iniciales, debido a las modificaciones que tienen lugar entre el conglomerante y el agua.

**GCI (*Global Competitiveness Index*):** Índice que intenta cuantificar el impacto de un número de factores clave que contribuyen a crear las condiciones para la competitividad con especial énfasis en el entorno macroeconómico, la calidad de

las instituciones del país, y el estado de la tecnología del país e infraestructura de soporte.

**Gradación:** V. Granulometría.

**Granulometría:** Distribución dimensional de las partículas de un suelo o agregado, la cual se expresa por la proporción en peso de material existente de cada tamaño.

**Grava:** Material granular resultante de la desintegración natural o la trituración de rocas, cuyas partículas pasan el tamiz de 75 mm (3") y son retenidas por el tamiz de 4.75 mm (tamiz # 4).

**Histograma:** Es la representación gráfica de las intensidades de grises que tiene cada imagen.

**Imagen digital:** Es una imagen que ha sido convertida en una matriz de píxeles, cada uno de los cuales tiene un valor asociado llamado su nivel de gris. Nota: Una imagen digital puede ser referida como una imagen cuando el significado destinado es claro por el contexto.

**Ligante:** Material que posee la propiedad de aglutinar partículas sólidas para formar una masa coherente.

**Ligante bituminoso:** Material adhesivo que contiene asfalto o alquitrán.

**Material cementante:** Sustancia que puede fraguar y endurecer en presencia de agua.

**Material granular:** Material resultante de la desintegración natural o la trituración de rocas, constituido fundamentalmente por partículas del tamaño de las gravas y las arenas.

**Materiales pétreos:** Materiales de construcción provenientes de piedras o rocas.

**Módulo de elasticidad:** Propiedad de los materiales elásticos, definida como la constante de proporcionalidad entre el esfuerzo aplicado y la deformación unitaria correspondiente en el rango elástico.

**Morfología matemática:** Es una teoría y técnica para el análisis y tratamiento de las estructuras geométricas, basada en la teoría de conjuntos, teoría de retículos, topología y funciones aleatorias.

**Mortero:** Mezcla de agregado fino, cemento portland y agua.

**Nivel freático:** Profundidad dentro del suelo a la cual el agua intersticial se encuentra a la presión atmosférica.

**Pavimento:** Estructura constituida por un conjunto de capas superpuestas, de diferentes materiales, adecuadamente compactados, que se construyen sobre la subrasante con el objeto de soportar las cargas del tránsito durante un período de varios años, brindando una superficie de rodamiento uniforme, cómoda y segura. 2. En algunos países se da este nombre únicamente a la capa de rodadura, recibiendo el nombre de firme el total de la estructura.

**Pavimento flexible:** Pavimento con capa de rodadura de tipo bituminoso y base granular o tratada con un ligante bituminoso, que sufre deformaciones elásticas de alguna consideración bajo las cargas normales del tránsito.

**Pérdida de agregados:** Desprendimiento de agregados de un tratamiento superficial, caracterizado por la aparición de una o más líneas descubiertas, paralelas a la dirección de aplicación.

**Preprocesamiento:** Una operación realizada antes de un proceso primario; por ejemplo, en reconocimiento de patrones, procesamiento en el que los patrones se simplifican para hacer la clasificación más fácil.

**Procesamiento de imagen:** La manipulación de imágenes por computador.

**Reconocimiento de patrones:** El análisis, la descripción, identificación y clasificación de objetos u otras regularidades significativas por medios automáticos o semiautomáticos.

**Red vial secundaria:** Carreteras departamentales, municipales, vecinales y otros.

**Red vial terciaria:** Vías rurales.

**Resistencia:** Esfuerzo necesario para alcanzar la rotura de un material. 2. Término genérico para indicar la aptitud de un material para resistir esfuerzos o deformaciones inducidos por fuerzas exteriores.

**Rigidez:** Característica de un material que le permite soportar esfuerzos de alta magnitud sin deformaciones apreciables. 2. Módulo dinámico de los asfaltos y las mezclas asfálticas, el cual establece una relación funcional que vincula las tensiones aplicadas y las deformaciones resultantes para cada condición de temperatura y tiempo o frecuencia de aplicación de las cargas.

**Rugosidad:** Distorsión de la superficie de una vía que da lugar a una conducción incómoda e insegura. Incluye irregularidades superficiales del pavimento con

dimensiones horizontales superiores a 500 mm y dimensiones verticales que excedan las tolerancias de la especificación del proyecto. 2. Respuesta dinámica acumulada del perfil longitudinal de un pavimento, al ser recorrido por un vehículo normal o por un dispositivo experimental de similar respuesta dinámica denominado rugosímetro.

**Ruido:** Datos irrelevantes que dificultan el reconocimiento e interpretación de los datos de interés en el procesamiento digital de imágenes.

**Segmentación:** Etapa del procesamiento digital de imágenes que permiten la separación y la localización de los objetos presentes en una imagen para simplificar la representación. Consiste en agrupar y delimitar la imagen en regiones de interés a partir de atributos homogéneos o características individuales.

**Subbase:** Capa de un pavimento asfáltico que se encuentra inmediatamente debajo de la base. Su colocación se puede omitir cuando el suelo de subrasante sea granular con elevada capacidad de soporte.

**Subdrén:** Excavación en forma de zanja, rellena con materiales permeables, que aleja las aguas o impide que ellas alcancen niveles perjudiciales para el pavimento.

**Subdrenaje:** Conjunto de elementos denominados subdrenes, que permiten captar y desalojar el agua que se infiltra en el piso o el suelo.

**Subrasante:** Capa de suelo preparada para soportar la estructura del pavimento.

**Suelo fino:** Suelo cuyas partículas tienen tamaño menor de 75  $\mu\text{m}$  de diámetro (también conocido como tamiz # 200).

**Tamiz:** Aparato, en un laboratorio, usado para separar tamaños de material, y donde las aberturas son cuadradas.

**Textura:** En procesamiento de imágenes, un atributo que representa la disposición espacial de los niveles de grises de los píxeles en una región.

**Tratamiento superficial:** Aplicación de un ligante bituminoso en estado líquido seguido de la extensión y compactación de una capa de gravilla de tamaño uniforme, en una o varias operaciones sucesivas.

**Umbralización:** Técnica de segmentación basada en un umbral que consiste en dividir el histograma de la imagen, conservando los píxeles que corresponden al nivel de intensidad del objeto y despreciando aquellos que corresponden al fondo.

## RESUMEN

### TÍTULO

**HERRAMIENTA DE SOFTWARE PARA EL RECONOCIMIENTO DE FALLAS TIPO DESPRENDIMIENTOS EN PAVIMENTO FLEXIBLE<sup>1</sup>**

### AUTORES

**Miguel Ángel Alarcón Sanabria<sup>2</sup>**  
**Jahir Augusto Saavedra García<sup>2</sup>**

**PALABRAS CLAVE:** Pavimento flexible, fallas tipo desprendimientos, cabezas duras, descascaramiento, baches, procesamiento digital de imágenes.

**DESCRIPCIÓN:** Las fallas tipo desprendimientos en pavimento flexible, generalmente son originadas por defectos constructivos, deficiencia de espesores en las capas del pavimento y por la retención de agua en zonas fisuradas o de escasa permeabilidad, en combinación con el continuo y pesado flujo de tránsito.

El procesamiento digital de imágenes permite automatizar los procesos para la detección de daños e inspección de pavimento. Actualmente en Colombia la detección de daños se realiza manualmente, siendo un procedimiento lento, peligroso, subjetivo y con elevados costos en mano de obra.

Dado lo anterior se propone desarrollar una herramienta de *software* que automatice la detección en imágenes digitales de fallas tipo desprendimiento en pavimento flexible, compuesto por daños denominados cabezas duras, descascaramiento y baches.

Para el desarrollo se tiene en cuenta dos algoritmos, uno para la detección de la falla cabezas duras y otro para las fallas descascaramiento y baches, que aplican técnicas de acondicionamiento como filtro de mediana, ajuste de contraste, y corrección de iluminación; técnicas de segmentación por umbralización local y contorno activo; operaciones morfológicas de apertura y dilatación para resaltar la representación de la falla; posteriormente se utilizan propiedades de textura y forma para eliminación de ruido y extracción de características para determinar los patrones de clasificación. Por último, se aplica la técnica de máquinas de soporte vectorial para la clasificación del tipo de daño.

Cada algoritmo genera como resultado una imagen, que son sobrepuestas para obtener una sola imagen. Luego se extraen las características de la imagen resultante como entradas para el primer clasificador que discriminará entre la clase cabezas duras y la clase *pothole*. Posteriormente, las secciones clasificadas como *pothole* ingresan a un segundo clasificador binario, que discrimina entre la clase descascaramiento y la clase bache. Cada clasificador se basa en la técnica de máquinas de soporte vectorial no lineal.

---

<sup>1</sup> Trabajo de Grado en la Modalidad de Investigación.

<sup>2</sup> Facultad de Ingenierías Físico Mecánicas. Escuela de Ingeniería de Sistemas e Informática. Director: PhD. Hernán Porras Díaz. Codirector: MSc. Duván Yahir Sanabria Echeverry.

## ABSTRACT

### TITTLE

#### SOFTWARE TOOL FOR THE RECOGNITION THE DETACHMENT DISTRESS TYPE IN FLEXIBLE PAVEMENT<sup>3</sup>

### AUTHORS

Miguel Ángel Alarcón Sanabria<sup>4</sup>

Jahir Augusto Saavedra García<sup>4</sup>

**KEYWORDS:** Flexible pavement, roadway distresses, *cabezas duras*, *descascamiento*, *baches*, pothole, digital image processing.

**DESCRIPTION:** The detachment distress types in flexible pavement are generally originated by constructive defects, deficiency of thickness in the capes of the pavement. It is also caused by the retention of water in cracked areas or with lack of permeability in combination with the continuous and heavy flow of transit.

The digital image processing (DIP) allows to automate the processes to detect the distress and the inspection of the pavement. Currently, in Colombia the detection of distress is done manually but this process is slow, dangerous, subjective and expensive.

Therefore, it is proposed to develop a software tool which automates and detects the surface distress in flexible pavement composed by distress called *cabezas duras*, *descascamiento* and *baches* (potholes).

In the development of the tool is mainly taken into account two algorithms, one of them is to detect the distress type of the *cabezas duras* and the other is to detect the distress type of *descascamiento* and *baches* (potholes) which apply the techniques for the conditioning of the images such as the median filter, contrast adjustment and correction of illumination (homogenization). On the other hand, the segmentation techniques by local threshold and active contour; morphological operations of opening and dilation are used to highlight the representation of the distress and the properties of texture and shape to eliminate noise.

Each algorithm produces an image, these images are overlapped to obtain only one image. Then, the features of the resulting image are extracted as entries for the classifier which will discriminate between the *cabezas duras* type and the pothole type (*hueco*). Subsequently, the classified sections as pothole will be entered as a second binary classifier that will discriminate between the *descascamiento* type and the *bache* type. Each classifier is based in the non-linear support vector machine technique.

---

<sup>3</sup> Grade work, research modality.

<sup>4</sup> Physical- Mechanical Engineering Faculty. Systems Engineering and Computer Science School. Director: PhD. Hernán Porras Díaz Codirector: MSc. Duván Yahír Sanabria Echeverry.

## INTRODUCCIÓN

El presente proyecto se enfoca en la detección y reconocimiento de fallas tipo desprendimiento en pavimento flexible, ésta categoría se compone de tres deterioros: cabezas duras, descascaramiento y baches.

La detección y el reconocimiento de fallas en el pavimento es un proceso indispensable para determinar el estado de las vías aplicando metodologías para la inspección de pavimentos y llevar a cabo obras encaminadas al mantenimiento y rehabilitación de las vías.

En un mundo globalizado como el de hoy, tener una red vial en adecuadas condiciones, se convierte en un reto cuyo caso el mantenimiento vial se convierte en un requerimiento básico para tener una economía competitiva.

La red vial es semejante al sistema circulatorio humano, si éste no funciona de manera adecuada, los procesos y otros sistemas relacionados no funcionarían de la mejor manera. Esta realidad ha sido entendida por aquellos países que tienen alto grado de desarrollo, y saben que la velocidad de la comunicación y la movilidad son factores importantes, por lo que el mantenimiento de la red vial es de interés nacional e internacional. Igualmente reducir las finanzas públicas y el déficit por restricción de presupuestos para el mantenimiento de la red vial se ha convertido en un reto de marca mayor, por tanto se exploran soluciones a esta problemática como son los sistemas de inspección automatizado de daños, que reducen el factor subjetivo humano de inspección, el tiempo y se efectúa a menor costo [1].

En cuanto a la calidad de las carreteras (que es uno de los componentes que están contemplándose, el GCI (*Global Competitiveness Index*) mediante la inclusión de un promedio ponderado de diversos componentes para medir un aspecto diferente de la competitividad), Colombia ocupa el puesto 126 entre 144 naciones, una posición similar a la de Lesoto (110) o Uganda (110) y muy inferior a la de Kenia (72), Nicaragua (75) o República Dominicana (62). Esta situación sumada al rezago de otras modalidades de la red de transporte reduce drásticamente la competitividad de la economía y más aún por los numerosos TLC que están operando o que entrarán en vigencia durante los próximos años. También otra de las causas de la escasa gobernabilidad son las regiones apartadas e incomunicadas por falta de vías en el país [2].

Lo anterior es corroborado con los datos de la calidad de infraestructura vial regional que evidencia el estado de las redes viales secundarias y terciarias donde cerca del 62 % se encuentra en regular estado y el 27 % en mal estado, que constituyen cerca del 90 % de las vías del país. Además, cabe destacar que las vías son vitales para el desarrollo regional y la disminución de la pobreza rural y urbana. Igualmente cabe señalar la ausencia de inventarios precisos en la ejecución de obras viales [3] [20].

Por otra parte, el mal estado del pavimento en los centros urbanos y en especial la presencia de baches, generan crecientes restricciones de capacidad vehicular, aumentando la congestión en el tráfico [4]. También aumenta la accidentalidad causada por el deterioro del pavimento, que hace que la nación, los departamentos y los municipios estén expuestos a millonarias demandas para indemnización de familiares o personas involucradas en accidentes de tránsito.

Además, el proceso de levantamiento de daños en campo, se realiza de forma manual y la inspección es visual, originando que el procedimiento sea lento, subjetivo, costoso y peligroso. El procesamiento digital de imágenes permite la automatización de los procesos para la detección de daños en carretera siendo uno de los parámetros fundamentales para el cálculo del índice de la condición del pavimento (PCI, por su sigla en inglés) y aporte en la toma de decisiones para el mantenimiento y rehabilitación de las vías.

También existe una gran variedad de daños en pavimento flexible clasificados en diferentes categorías por su morfología, origen y dimensión. La investigación contribuye al macroproyecto del grupo de investigación Geomática, gestión y optimización de sistemas de la Universidad Industrial de Santander - UIS, encaminado a los planes de gestión vial para la rehabilitación y mantenimiento de vías pavimentadas en Colombia.

Por todo lo anterior, el proyecto de investigación se centra en el reconocimiento de tres fallas de tipo desprendimiento, que son: cabezas duras, descascamiento y baches, donde las dos últimas son causantes de accidentalidad vehicular. Igualmente con la detección de estos tipos de daños, se busca complementar las investigaciones relacionadas con la identificación de deterioros en el pavimento llevadas a cabo en el grupo de investigación Geomática. También se requiere consolidar los algoritmos relacionados con la detección de diferentes tipos de daños en el pavimento. Además, con la detección de fallas en vías pavimentadas se procura identificar la mayoría de daños y evitar la aseveración de los deterioros, para el cálculo del PCI, la disminución de costos, los tiempos de inspección y toma de decisiones con base en metodologías para la ejecución de acciones encaminadas a la reparación del pavimento.

## 1. OBJETIVOS

### 1.1 OBJETIVO GENERAL

Desarrollar una herramienta de *software* que permita detectar fallas tipo desprendimientos en pavimento flexible.

### 1.2 OBJETIVOS ESPECÍFICOS

- Realizar el levantamiento de daños mediante el instrumento de captura seleccionado
- Caracterizar los daños tipo desprendimiento de pavimento flexible
- Implementar los algoritmos para la segmentación y detección de fallas tipo desprendimiento
- Desarrollar una herramienta de *software* que permita integrar los diferentes algoritmos implementados para la detección de fallas en pavimento flexible
- Validar los resultados obtenidos mediante el algoritmo desarrollado y por inspección visual humana

## **2. JUSTIFICACIÓN**

### **2.1 DEFINICIÓN DEL PROBLEMA**

La detección y clasificación de fallas en el pavimento es un proceso necesario para conocer el estado de las vías y así llevar a cabo obras encaminadas al mantenimiento y rehabilitación de las vías.

Igualmente la tendencia de los gobiernos está en equilibrar las finanzas públicas y reducir el déficit mediante la restricción del presupuesto, donde el mantenimiento de la red vial se ha convertido en un reto a alcanzar [1].

En el contexto internacional los países líderes en el desarrollo de métodos para detección de fallas en la malla vial, son China y Estados Unidos, debido a que han realizado numerosos estudios para crear y optimizar los métodos de detección y clasificación de fallas y a su vez desarrollar la tecnología y el procedimiento para la adquisición y el procesamiento de daños en el pavimento en tiempo real, cada vez con mejor eficiencia y precisión. En lo que se refiere al estudio en el contexto nacional el problema no se ha profundizado a fondo en comparación con otros países.

Hay diversos métodos para identificación y recolección de los datos de las fallas en el pavimento, ya sean grietas cuyos métodos de imagen analógicas están distribuidos en fotografías, video e imagen digital, los utilizados para pavimento rugoso y suave que utiliza la tecnología de sensores de tipo laser acústico e infrarrojo; por último están las fallas de junta que también utilizan sensores con menor precisión y confianza en los datos obtenidos [5].

La gestión en la investigación de este proyecto, contribuye al trabajo del grupo de investigación Geomática de la UIS, para automatizar la detección de estas fallas de pavimento en Colombia y encaminar los planes de gestión vial hacia la rehabilitación y mantenimiento de vías pavimentadas.

### **2.2 IMPACTO ESPERADO**

El grupo de Investigación Geomática, gestión y optimización de sistemas, está profundizando en la línea de investigación “avances en sistemas automáticos para el apoyo de los procesos para la gestión eficiente de vías pavimentadas”. Además, ha hecho estudios de investigación en la detección y reconocimiento de fallas en pavimento flexible y rígido con la finalidad de automatizar la detección de daños en vías pavimentadas. Se espera que el proyecto de investigación, detecte las fallas tipo desprendimiento denominadas cabezas duras, descascaramiento y baches en el pavimento flexible.

### 2.3 VIABILIDAD

Para la realización de este proyecto se cuenta con el apoyo del grupo de Investigación Geomática, gestión y optimización de sistemas, perteneciente a la Escuela de Ingeniería Civil de la Universidad Industrial de Santander. También se cuenta con el respaldo de expertos en el diseño de pavimentos y en materiales de construcción. Además, se cuenta con especialistas en ingeniería de pavimentos y tratamiento digital de imágenes.

Por otra parte, en esta área de conocimiento la comunidad científica mundial de países desarrollados ha avanzado eficientemente en tecnologías para la inspección automática de vías pavimentadas, con el fin de minimizar costos y evitar riesgos humanos durante el levantamiento de datos, aunque inicialmente los costos por la tecnología adquirida son elevados.

### 2.4 ESTADO DEL ARTE

En el contexto general, nacional e internacional las investigaciones se han encaminado al reconocimiento de grietas o fisuras. Por consiguiente, las investigaciones en detección de daños tipo descascaramiento y baches han sido escasas.

En el año 2011 el Departamento de Ingeniería Eléctrica & Ciencias de la Computación de la Universidad de Toledo propuso un método de segmentación del pavimento basado en un algoritmo genético y la teoría de la entropía para la detección y clasificación del deterioro del pavimento, en que el algoritmo genético es utilizado para obtener el mejor umbral de segmentación [6].

En el mismo año, la Universidad de Toledo publicó un artículo donde se detectan baches (hueco) y su medida de severidad, proyectando una línea láser sobre el pavimento y aplicando el método *Template Matching* se define la deformación de la línea láser detectada, para la detección de daños tipo hundimiento (hueco) u obstáculo [7].

En el año 2010 la Facultad de Matemáticas y Ciencias de la Computación de la Universidad de Fuzhou, China, publicó un artículo donde los autores proponen un método de reconocimiento para distinguir baches de grietas y otros defectos en el pavimento que son segmentados utilizando modelos de ecuaciones diferenciales parciales, este método utiliza máquinas de soporte vectorial no lineal para identificar si el área interna de un objetivo con falla es un bache o no [8].

Por otra parte, la falla denominada cabezas duras, es definida únicamente en el territorio nacional colombiano. Por tanto, se encontró un documento de la Universidad Técnica de Dinamarca donde se detectan nanopartículas en imágenes TEM (por su sigla en inglés, *Transmission Electron Microscopy*) [9], cuya segmentación realizada en dicho trabajo se asemeja a la granularidad de la falla cabezas duras en pavimento flexible.

Respecto a la tecnología utilizada en el país, el sistema de identificación visual humana sigue siendo el predominante, que ha ido evolucionando a nivel mundial con el surgimiento de plataformas móviles para la inspección automática de pavimentos. También se destaca el registro de los datos mediante dispositivos móviles que permiten eliminar los formatos de papel y la posterior digitalización.

Existen sistemas automáticos y semiautomáticos para captación de datos. En cuanto a los semiautomáticos existen equipos que registran fotografías de la superficie del pavimento e indican la abscisa en la imagen digital resultante. Sin embargo, el proceso de interpretación de las imágenes es por inspección visual humana.

Por otra parte, en los sistemas automáticos están disponibles equipos que captan imágenes mediante escaneo de líneas infrarrojas con el objetivo de captar la profundidad de los daños. También se utilizan sistemas de iluminación artificial para homogenizar el contraste de las imágenes y resaltar los defectos superficiales, resolviendo los problemas de iluminación no uniforme y sombras que se puedan presentar sobre la vía. Adicionalmente, las imágenes pueden ser georreferenciadas mediante GPS (del inglés, *Global Positioning System*). El procesamiento de la información recolectada en campo se realiza con *software* especializado para la detección y análisis.

### 3. MARCO TEÓRICO

#### 3.1 PAVIMENTO

Se denomina pavimento a la estructura constituida por capas de materiales cuya función es permitir la operación rápida, cómoda y segura de los vehículos en una carretera [10]. Los tipos de pavimento más conocidos en el medio son: pavimento flexible, pavimento de capa asfáltica gruesa, pavimento rígido, pavimento semirrígido, pavimento articulado, compuesto, pavimento de estructura inversa.

El pavimento está constituido por un conjunto de capas superpuestas, relativamente horizontales, que se diseñan y construyen técnicamente con materiales apropiados y adecuadamente compactados. Estas estructuras estratificadas se apoyan sobre un suelo o capa denominada subrasante, de una vía obtenida por el movimiento de tierras en el proceso de exploración y que han de resistir adecuadamente los esfuerzos que las cargas repetidas del tránsito le transmiten durante el período para el cual fue diseñada la estructura del pavimento [11].

Un pavimento para cumplir adecuadamente sus funciones debe reunir los siguientes requisitos:

- Ser resistente a la acción de las cargas impuestas por el tránsito
- Ser resistente a la intemperie
- Presentar una textura superficial adaptada a las velocidades previstas de circulación de los vehículos, por cuanto ella tiene una decisiva influencia en la seguridad vial. Además, debe ser resistente al desgaste producido por el efecto abrasivo de las llantas de los vehículos
- Debe presentar una regularidad superficial, tanto transversal como longitudinal, que permitan una adecuada comodidad a los usuarios en función de las longitudes de onda de las deformaciones y de la velocidad de circulación
- Debe ser durable
- Presentar condiciones adecuadas respecto al drenaje
- El ruido de rodadura, en el interior de los vehículos que afectan al usuario, así como en el exterior, que influye en el entorno, debe ser adecuadamente moderado
- Debe ser económico

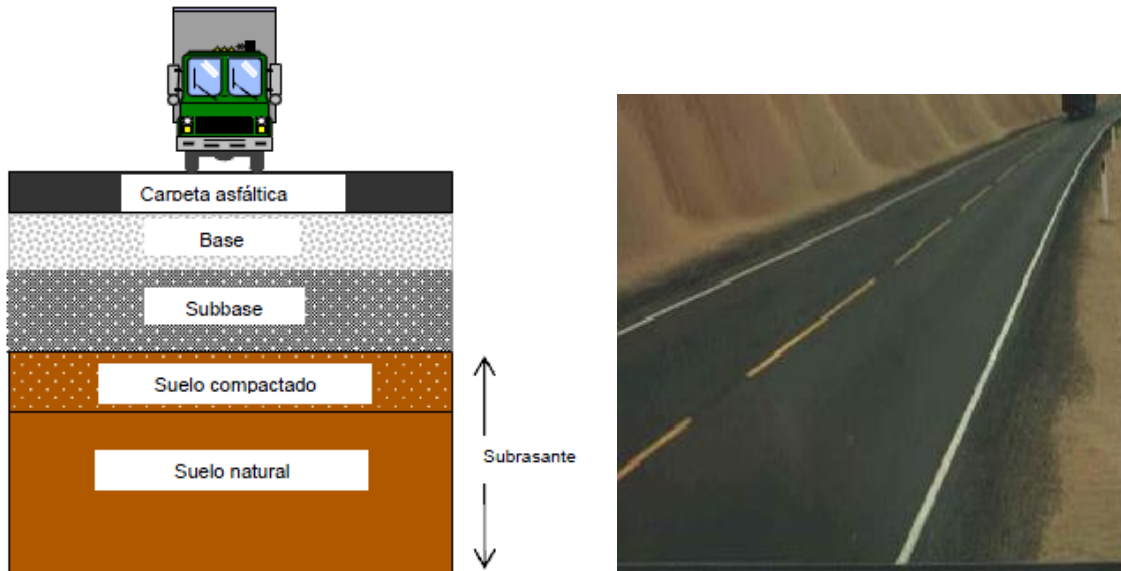
- Debe poseer el color adecuado para evitar reflejos y deslumbramientos, y ofrecer una adecuada seguridad al tránsito

### 3.2 PAVIMENTO FLEXIBLE

Este tipo de pavimentos están formados por una carpeta bituminosa apoyada generalmente sobre dos capas de material granular no rígidas, la base y la subbase, las cuales se asientan sobre un suelo o capa denominada subrasante. No obstante puede prescindirse de cualquiera de estas capas (base o subbase), dependiendo de las necesidades particulares de cada obra. Se le denomina pavimento flexible debido a las características visco-elásticas del bitumen, ya que las cargas producen deformaciones más altas en comparación con otros tipos de pavimentos [10] [11] [12].

#### 3.2.1 Capas del Pavimento Flexible

**Figura 1.** Estructura de pavimento flexible [10]



### **3.2.1.1 Carpeta asfáltica o capa superficial**

Además de su función como una parte estructural del pavimento, la capa superficial se debe proyectar para resistir las fuerzas abrasivas de tráfico, limitar la cantidad de agua superficial que penetra en el pavimento, proveer una superficie resistente a deslizamiento y proporcionar una superficie uniforme y estable de color y textura conveniente para proveer un excelente servicio a los usuarios de la vía. La capa superficial también debe ser durable, capaz de resistir fracturas y desmoronamientos sin llegar a ser inestable en las condiciones del tráfico y del clima.

Comúnmente construida sobre una capa de base, la capa superficial de una estructura de pavimento flexible consta de una mezcla de agregados minerales y de materiales bituminosos. El éxito de tal capa depende sobre todo de la obtención de una mezcla con la óptima gradación de agregado y porcentaje adecuado de ligante bituminoso [10] [11] [12].

### **3.2.1.2 Base**

La capa de base es la porción de la estructura de pavimento flexible inmediatamente debajo de la capa superficial. La función fundamental de esta capa es proporcionar un elemento resistente que atenúe los esfuerzos producidos por las cargas de tránsito para transmitirlos a la subrasante. La base comúnmente consta de agregados como piedra triturada, escoria triturada o grava triturada o sin triturar y arena, o la combinación de estos materiales. Como la parte inferior de esta capa va a estar sometida a menores esfuerzos, es posible reducir las características de resistencia mecánica del material en esta porción y transformarla en dos capas, la superior o capa de base propiamente dicha y la capa inferior denominada subbase. Las especificaciones para materiales de capa de base son superiores a las de materiales de subbase en los requerimientos de resistencia, estabilidad, dureza, tipos de agregados y gradación [10] [11] [12].

### **3.2.1.3 Subbase**

La capa de subbase se usa en general para reducir el costo total de construcción del pavimento. La subbase puede omitirse, si la estructura requerida de pavimento es relativamente delgada o si los suelos de la subrasante son de alta calidad [10] [11] [12].

Además de su función principal, las capas de subbase deben cumplir con otras funciones secundarias como [10]:

- Evitar que los suelos de grano fino del lecho del camino se filtren dentro de las capas de base. Se deben especificar materiales bien gradados, si la subbase está destinada a servir para este propósito
- Para ayudar a evitar la acumulación de agua libre dentro o debajo de la estructura del pavimento. Se debe especificar material que drene el agua de una forma relativamente rápida y se deben proporcionar los medios de coleccionar y eliminar el agua acumulada de la subbase
- Impedir que el agua de la capa subrasante ascienda por capilaridad y evitar que el pavimento sea absorbido por la subrasante
- Transmitir en forma adecuada los esfuerzos a la subrasante
- En los cortes de roca, proveer una plataforma de trabajo para equipo de construcción o para subsecuentes capas del pavimento
- Disminución de las deformaciones. Algunos cambios volumétricos de la capa subrasante, generalmente asociados a cambios en su contenido de agua (expansiones), o a cambios extremos de temperatura (heladas), pueden absorberse con la capa subbase, impidiendo que dichas deformaciones se reflejen en la superficie de rodamiento

#### **3.2.1.4 Subrasante**

La subrasante es aquella parte de la estructura que tiene como función servir de soporte a las otras capas del pavimento. De la calidad de esta capa depende en gran medida el espesor que debe tener un pavimento [10] [11] [12].

Para dimensionar un pavimento es necesario determinar la capacidad para soportar cargas de los suelos que servirán de fundación a las capas de la estructura, se debe también tener en cuenta la sensibilidad del suelo a la humedad, tanto en lo que refiere a la resistencia como a las eventuales variaciones de volumen (hinchamiento y retracción) ya que los cambios volumétricos del suelo de la subrasante de tipo expansivo puede causar graves problemas a cualquier estructura que se apoye sobre estos. Para contrarrestar este tipo de problemas se debe estabilizar el suelo usando algunos aditivos como la cal o evitando los cambios de humedad (impermeabilizando la estructura).

Como parámetro de evaluación de esta capa se emplea la capacidad de soporte o resistencia a la deformación por esfuerzo cortante bajo las cargas del tránsito. La subrasante se puede construir con suelos en su estado natural o suelos con algún proceso de mejoramiento tal como la estabilización mecánica o química, entre otras aplicables. Por esta razón, cuando se construye un pavimento es de gran

importancia tener en cuenta el tipo de suelo sobre el cual se va a construir (subrasante), así como la determinación de los materiales y espesores de las capas (subbase, base y carpeta asfáltica) que constituyen el pavimento.

### 3.2.2 Materiales Utilizados en las Capas de Pavimento Flexible

En bases, subbases y rellenos de carretera se hace uso de materiales granulares. Estos materiales también se usan en combinaciones con un material cementante para formar concretos para bases, subbases, superficies de desgaste y estructuras de drenajes. Las fuentes de dichos materiales incluyen los depósitos naturales de arena y grava, los pavimentos pulverizados de concreto y asfalto, el material pétreo resquebrajado y la escoria de altos hornos. Dichos materiales deben cumplir unos requisitos de calidad como resistencia al desgaste (dureza), resistencia al pulimento, resistencia mecánica, entre otros, con el fin de garantizar un buen comportamiento de la estructura [10] [11] [12].

**Figura 2.** Algunos materiales utilizados en el diseño de pavimentos [10]



Para poder lograr una alta densidad durante el proceso de compactación del pavimento flexible, es necesario que los agregados tengan una buena distribución gradual, que se logra con la diversidad en el tamaño y la forma de los agregados, dicha variedad en los agregados facilita el acomodamiento y entrecruzado entre los mismos y por lo tanto esto hace que la estructura granular presente una alta resistencia mecánica al flujo del tránsito.

En Colombia el Instituto Nacional de Vías (INVIAS), recomienda que el conjunto de agregados fino, grueso y grava varíe en su tamaño con la utilización de un tamiz específico para la selección del material granular [10]. La Tabla 1 contiene los tamaños de tamiz utilizados en la selección del material granular para la construcción de pavimento flexible.

**Tabla 1.** Tamaños de tamiz para la selección del material granular [10]

<b>Tamiz</b>	
<b>Tamaño</b>	<b>Equivalencia</b>
N° 200	75 µm
N° 40	425 µm
N° 10	2.0 mm
N° 4	4.75 mm
3/8"	9.5 mm
1/2"	19.0 mm
1"	25.0 mm
1 1/2"	37.5 mm
2"	50.0 mm

### **3.3 FALLAS TIPO DESPRENDIMIENTOS EN PAVIMENTO FLEXIBLE**

Las patologías del pavimento flexible se clasifican en cinco categorías [10]:


- Fisuras
- Deformaciones
- **Desprendimientos**
- Daños Superficiales
- Otros Daños

Para este caso particular, se centrará en las fallas de tipo desprendimientos que son cabezas duras, descascaramiento y baches.

#### **3.3.1 Cabeza Duras**

Este tipo de desprendimiento se caracteriza por la presencia de agregados expuestos fuera del mortero (arena-asfalto), que puede llegar a aumentar la rugosidad del pavimento, provocando ruido excesivo para el conductor [10] [11] [12].

**Figura 3.** Desprendimiento tipo cabeza dura [12]



### **Causas**

- Uso de agregados gruesos con tamaños inadecuados
- Distribución granulométrica deficiente en el rango de las arenas
- Diversidad en la dureza de los agregados
- Separación de los agregados durante su manejo en obra


**Unidad de Medición:** Se mide en metros cuadrados ( $m^2$ ) y no tiene ningún grado de severidad asociado.

**Evolución probable:** Pérdida de agregados, descascaramiento.

### **3.3.2 Descascaramiento:**

Este deterioro se produce al ocurrir desprendimiento de parte de la capa asfáltica superficial sin llegar a afectar las capas asfálticas subyacentes [10] [11] [12].

**Figura 4:** Descascaramiento [12]



### **Causas**

- Limpiezas insuficientes previas al tratamiento superficial
- Esparcimiento no homogéneo del ligante (asfalto)
- Ligante inadecuado
- Dosificación árido (pétreo) – ligante (asfalto) inadecuada
- Colocación con lluvia o exceso de agua en la capa de apoyo, que produce de laminación
- Compactación deficiente
- Fraguado incompleto después de apertura al tránsito
- Envejecimiento del ligante (asfalto)
- Mezcla asfáltica muy permeable

### **Niveles de severidad**

- Baja: Profundidad menor a 10mm
- Media: Profundidad entre 10mm y 25mm
- Alta: Profundidad mayor a 25 mm


**Unidad de medición:** Se registra el área afectada para cada severidad en metros cuadrados ( $m^2$ ).

**Evolución probable:** piel de cocodrilo, bache.

### 3.3.3 Baches:

Es la desintegración total de la capa de rodadura y se puede extender a otras capas del pavimento, formando una cavidad de bordes profundos e irregulares [10] [11] [12].

**Figura 5.** Baches [12]



### Causas

Los baches se producen por conjunción de varias causas:

- Fundaciones y capas inferiores inestables
- Espesores insuficientes
- Defectos constructivos
- Retención de agua en zonas hundidas o fisuradas

- La acción abrasiva del tránsito sobre sectores localizados de mayor debilidad del pavimento o fisuradas
- O sobre áreas en las que se han desarrollado fisuras tipo piel de cocodrilo, que han alcanzado un alto nivel de severidad, provoca la desintegración y posterior remoción de parte de la superficie del pavimento, originando un bache
- Subdrenaje inadecuado

**Niveles de severidad:** Se definen tres niveles de severidad: Bajo, Medio y Alto; en función del área afectada y de la profundidad del bache, de acuerdo a la Tabla 2.

**Unidad de medición:** Se miden en metros cuadrados ( $m^2$ ) de área afectada, registrando la mayor severidad existente

**Evolución probable:** Destrucción de la estructura.

**Tabla 2.** Nivel de severidad de los baches [10]

Profundidad Máxima (cm)	Diámetro Promedio del Bache (cm)		
	Menor a 70	70-100	Mayor a 100
Menor de 2.5	Bajo	Bajo	Medio
De 2.5 a 5	Bajo	Medio	Alto
Mayor de 5	Medio	Medio	Alto

### 3.4 TRATAMIENTO DIGITAL DE IMÁGENES

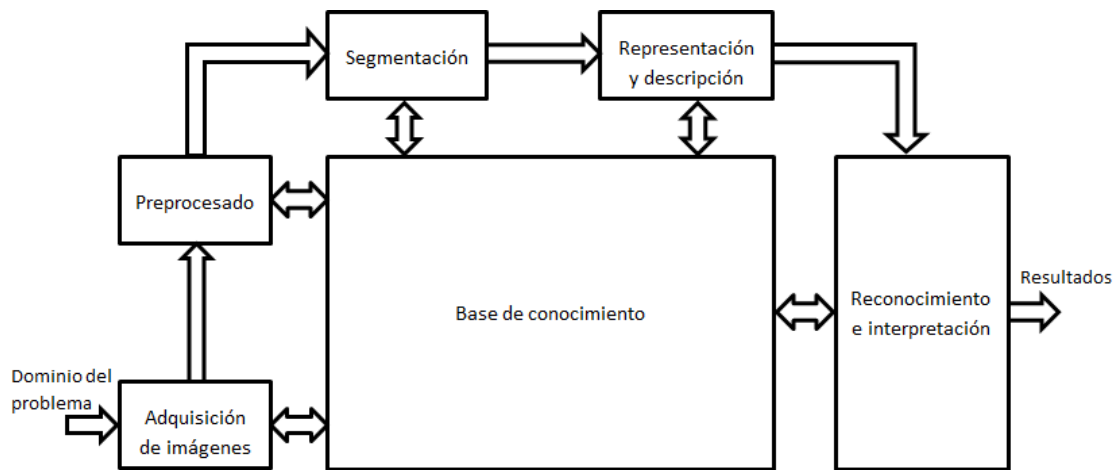
Los métodos de tratamiento digital de imágenes derivan de dos áreas principales de aplicación, la mejora de la información de la imagen y el procesamiento de los datos de la captura para la percepción autónoma por una máquina. Desde la década de los ochenta se incrementó su desarrollo con la construcción de equipos con mayor capacidad de cómputo y con la implementación de modelos matemáticos que permitían extraer las características de la imagen.

Una imagen puede ser definida como una función bidimensional  $f(x, y)$ , donde  $x$  y  $y$  son coordenadas espaciales (planas), y la amplitud de  $f$  en cualquier par de coordenadas  $(x, y)$  es llamada la intensidad o nivel de gris de la imagen en ese punto. Cuando  $x, y$  y la intensidad de valores de  $f$  son todos finitos, cantidades

discretas, la imagen se denomina imagen digital. Por lo anterior la imagen digital está compuesta de un número finito de elementos, cada uno de los cuales tiene una localización particular y valor, a estos elementos se les denomina píxeles [13].

Como lo muestra la Figura 6, el tratamiento digital de imágenes comprende las siguientes etapas: Adquisición de imágenes, preprocesado, segmentación, representación y descripción, reconocimiento e interpretación, y base de conocimiento [14].

**Figura 6.** Etapas procesamiento digital de imágenes [14]



Una vez, obtenida la imagen digital, la siguiente etapa trata del preprocesamiento de esa imagen. La función básica del preprocesamiento es la de mejorar la imagen de forma que se aumenten las posibilidades de éxito en los procesos posteriores.

La siguiente etapa trata de la segmentación, que consiste en dividir la imagen de entrada en partes constituyentes u objetos. En general el objetivo fundamental de la segmentación es el de extraer caracteres individuales, separando el objeto del fondo. A la salida del proceso de segmentación generalmente se obtienen los datos de los píxeles en forma binaria (1 ó 0), que constituyen el contorno de una región o todos los puntos de una región determinada. En cada caso es necesario convertir los datos a una forma adecuada para el procesamiento.

La representación es una parte de la solución para transformar los datos de píxel a una forma adecuada para ser posteriormente tratados. También se debe especificar un método para describir los datos de tal manera que se resalten los rasgos de interés. La descripción, también denominada selección de rasgos, consiste en

extraer alguna información cuantitativa de interés o que sean fundamentales para diferenciar una clase de objetos de otra.

La última etapa concluye en el reconocimiento e interpretación. El reconocimiento es el proceso de asignar una etiqueta a un objeto basándose en la información proporcionada por los descriptores. La interpretación implica asignar significado a un conjunto de entidades etiquetadas.

La base del conocimiento representa la interacción entre el dominio del problema y la interacción con los módulos del tratamiento digital de imágenes. Este conocimiento puede ser tan simple como detallar las regiones de una imagen donde se sabe que se ubica información de interés, limitando así la búsqueda que ha de realizarse para hallar tal información; o tan compleja, como una lista interrelacionada de todos los posibles defectos en un problema de inspección.

Como lo expresa Cuevas, Zaldívar y Pérez en su libro “Procesamiento Digital de Imágenes con *Matlab* y *Simulink*” [15], el objetivo del Procesamiento Digital de Imágenes (PDI) es interpretar alguna característica notable en la imagen. Es por ello que el PDI se divide en subsistemas, que son procesamiento de bajo nivel, procesamiento de nivel medio y procesamiento de alto nivel.

En el procesamiento de bajo nivel, se encuentran procesos que se realizan sobre imágenes correspondientes de suavizado, umbralización, eliminación de ruido, definición de borde, etc. Esta etapa suele conocerse también como preprocesado. En el de nivel medio, se definen procesos tales como definición de límites y extracción de características. En el nivel alto, se establecen relaciones semánticas entre los objetos de la descripción de la escena o clasificación.


#### 4. METODOLOGÍA DE IMPLEMENTACIÓN

Para el desarrollo de la herramienta *software* se utilizó la metodología del modelo de prototipado evolutivo, que permite mejorar progresivamente la herramienta. En esta metodología el concepto del sistema es desarrollado a medida que avanza el proyecto. Se comienza por diseñar e implementar las partes más importantes del programa en un prototipo, que es ampliado y refinado hasta que se termine. Finalmente, el prototipo se convierte en el producto final [28].

**Definición del problema:** Se identifican los requisitos conocidos y se perfilan las áreas donde sea necesaria una mayor definición.

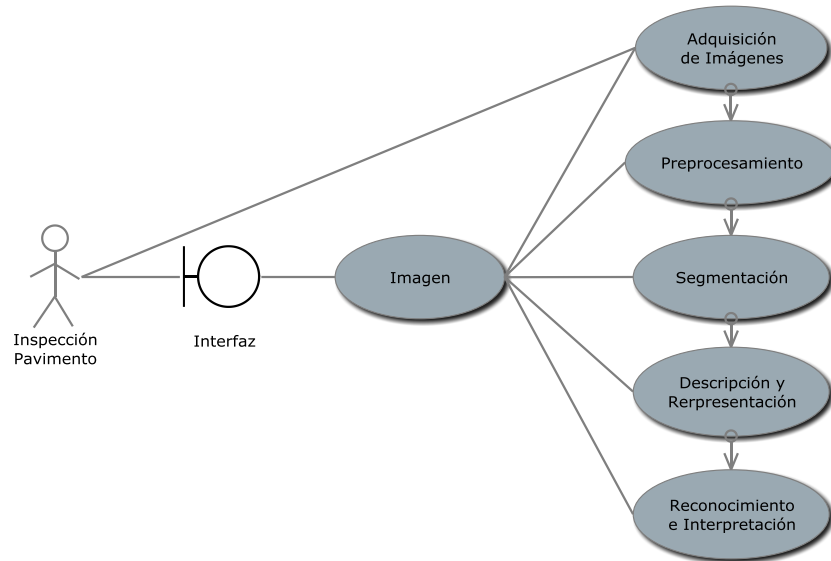
El requisito principal se centra en la detección de fallas tipo desprendimiento, representado en el diagrama de casos de uso (Figura 7).

**Figura 7.** Diagrama de casos de uso



Con base en el diagrama de casos de uso (Figura 7), podemos realizar un diagrama del modelo de análisis del desarrollo de la herramienta (Figura 8).

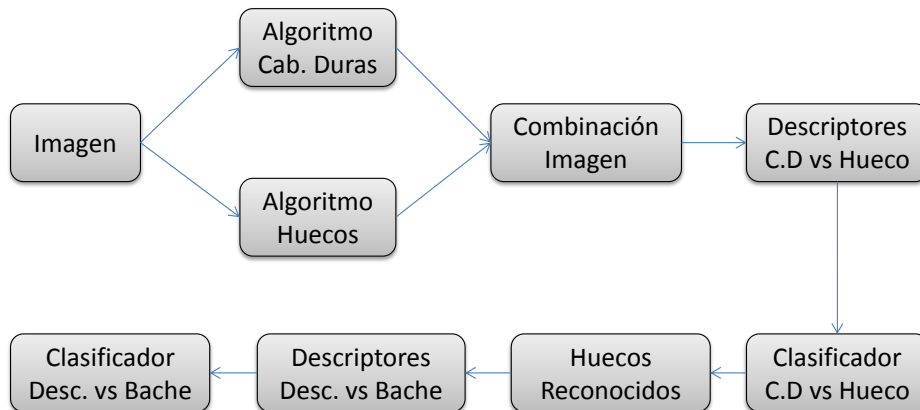
**Figura 8.** Diagrama del modelo de análisis



**Planeación:** Se establece un plan de trabajo para avanzar progresivamente hacia el objetivo general.


El siguiente diagrama (Figura 9) representa el diseño de la integración de los diferentes algoritmos implementados en la detección de fallas tipo desprendimiento.

**Figura 9.** Diagrama diseño de la integración de algoritmos



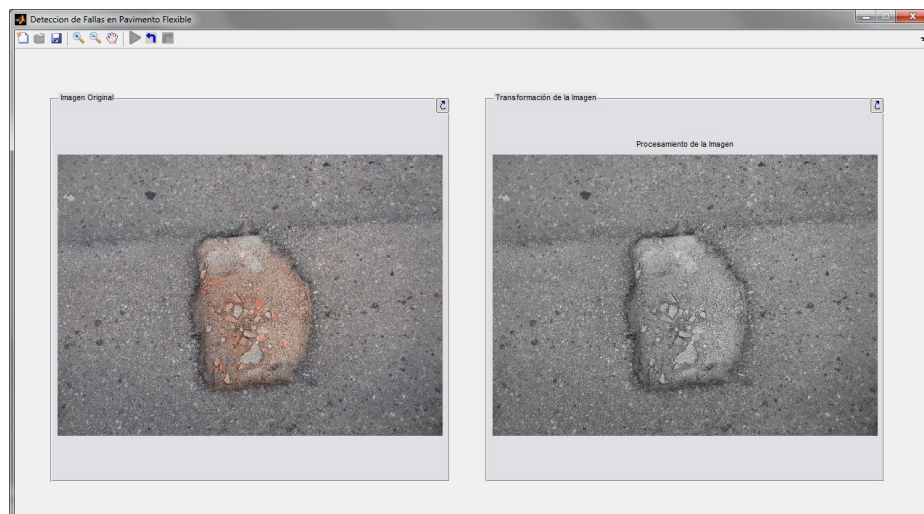
**Diseño rápido:** Se realiza un diseño rápido que se enfoca sobre en la UI (*User Interface*), aspectos visibles al usuario (Figura 10).

**Figura 10.** Diseño rápido interfaz usuario



**Construcción de prototipo:** Se construye el prototipo y se realizan pruebas de integración para descubrir errores de código.

**Figura 11.** Prototipo herramienta software



**Desarrollo del producto final:** Se realiza la entrega del prototipo final y la retroalimentación para refinar los requisitos de la herramienta *software*. Ver anexo A, anexo B, anexo C y anexo D.

## 5. ADQUISICIÓN DE IMÁGENES

Se selecciona la técnica de captación de datos con cámara digital para experimentar la inclusión de una línea de rayo láser proyectada con la finalidad de detectar mediante el parámetro de profundidad las fallas a evaluar consideradas, principalmente las fallas tipo descascaramiento y bache donde la característica de profundidad es una de los más relevantes.


Para la captación de las imágenes se utiliza una cámara Sony DSC-HX9V, que tiene una resolución de 3456 x 4608 píxeles de escaneo por área, sensor de imagen CMOS Exmor R de tamaño ½.3 pulgadas y filtro de color RGB.

A continuación se presentan los diferentes modelos implementados para realizar la captación y al final se presenta el modelo definitivo que se aplica en la investigación.

### 5.1 PRIMER MODELO DE ADQUISICIÓN

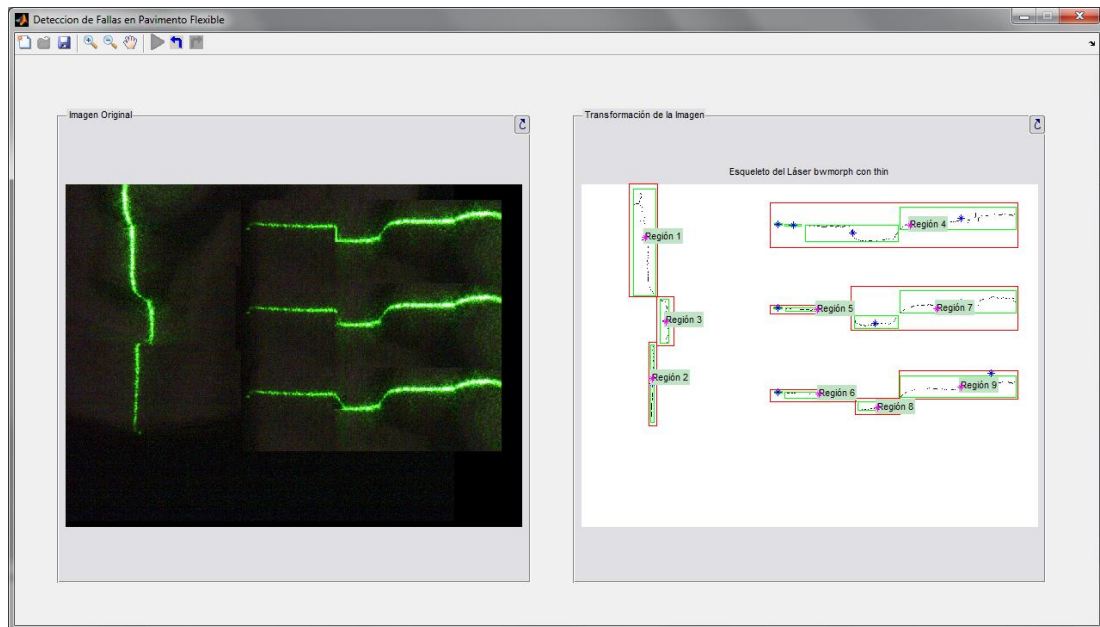
Para realizar las primeras pruebas con imágenes, se utilizaron imágenes que el grupo de investigación Geomática había captado mediante la proyección de un rayo láser sobre superficies oscuras con diferentes niveles de altura, para visualizar la difracción de la línea láser.

**Figura 12.** Imágenes de muestras de línea láser, primer modelo de adquisición



Este modelo únicamente fue tenido en cuenta para revisar la viabilidad del método de adquisición y realizar el primer prototipo de la herramienta *software* y las pruebas de segmentación por color de la línea láser, como lo muestra la Figura 13.

**Figura 13.** Pruebas del prototipo *software*




## 5.2 SEGUNDO MODELO DE ADQUISICIÓN

En el laboratorio de óptica de la Escuela de Física de la Universidad Industrial de Santander, se utilizó un rayo láser de 508 nm y un lente cilíndrico para proyectar la línea láser sobre diferentes fragmentos de carpeta asfáltica donados por la Corporación para la investigación y desarrollo de asfaltos en el sector transporte e industrial - CORASFALTOS.

La fuente del rayo láser es en color rojo con proyección de punto, se encuentra fijo mediante un brazo mecánico acoplado a una mesa del laboratorio de óptica. Fue necesario adecuar el sistema de proyección de manera que la línea láser se proyecte sobre el fragmento de carpeta asfáltica ubicado a una altura inferior al brazo y paralela a la superficie de la mesa.

El haz de rayo láser se enfoca en dirección al lente cilíndrico que transforma la proyección de punto en proyección de línea. Luego, se proyecta hacia un espejo plano para reflejar la línea láser sobre la carpeta asfáltica. La Figura 14 muestra el montaje realizado en el laboratorio de óptica.

**Figura 14.** Montaje segundo modelo de adquisición



Posteriormente, se captaron las imágenes con la difracción de la línea láser causada por los fragmentos de carpeta asfáltica de diferentes tamaños, como se muestra en la Figura 15.

**Figura 15.** Imágenes segundo modelo de adquisición




El modelo fue excluido debido a que las capas del pavimento flexible en Colombia no tienen una profundidad regular y estándar, por tanto el delta de la difracción de la línea láser no es un parámetro suficiente para identificar la profundidad de la capa afectada para clasificar el tipo de daño como bache o descascaramiento. Por lo anterior, fue necesario recurrir al tercer modelo de adquisición.

### 5.3 TERCER MODELO DE ADQUISICIÓN

La cámara se adapta a un brazo metálico y se ubica perpendicularmente a la superficie del pavimento a una altura aproximada de 1.6 metros, como se muestra en la Figura 16.

**Figura 16.** Tercer modelo de adquisición



Con el tercer modelo se captaron 100 imágenes por cada tipo de falla para un total de 300 imágenes. Estas fueron guardadas digitalmente en formato JPEG (*Joint Photographic Experts Group*), configurada a una resolución de 3456 x 4608 píxeles. Con base en la altura de 1,6 metros, cada imagen abarca aproximadamente un área de 1,65 metros de largo por 2,35 metros de ancho para alcanzar un detalle aproximado de 0.5 milímetros por píxel.

A continuación se muestran algunas de las imágenes captadas en el área metropolitana de Bucaramanga (Santander, Colombia), en el horario de 5:30 a.m. a 8 a.m. con el fin de evitar sombras e iluminación no uniforme.

**5.3.1 Imágenes de falla tipo cabezas duras**



**5.3.2 Imágenes de falla tipo descascaramiento**



**5.3.3 Imágenes de falla tipo bache**



## 6. PREPROCESAMIENTO

El procesamiento digital de las imágenes - PDI se realizó mediante la herramienta *software* Matlab R2013a (8.1.0.604) de 64-bit usando el *toolbox* de imágenes compuesto por funciones recursivas que permiten realizar operaciones de PDI. Además, Matlab por ser un lenguaje de código interpretado permite realizar operaciones con manejo de memoria, punteros, librerías de inclusión, o llamado de funciones, entre otros detalles.

Por otra parte, para el acondicionamiento, en primer lugar se transforma la imagen de color RGB (*Red Green Blue*) a imagen en escala de grises.

El cambio de tipo de imagen representa una disminución en el costo computacional, debido a que la imagen de tipo RGB se representa en *matrices* de tamaño  $M \times N \times 3$ , donde cada píxel está formado por una tripleta de valores correspondientes a los componentes rojo, verde y azul. Mientras que la imagen a escala de grises es una matriz de datos cuyos valores son escalados para representar una intensidad determinada. Además, según la literatura para la detección de las fallas en pavimento se utilizan imágenes monocromáticas [13] [14] [15] [16] [17] [19].

### 6.1 CARACTERIZACIÓN DE LAS FALLAS TIPO DESPRENDIMIENTO EN PAVIMENTO FLEXIBLE

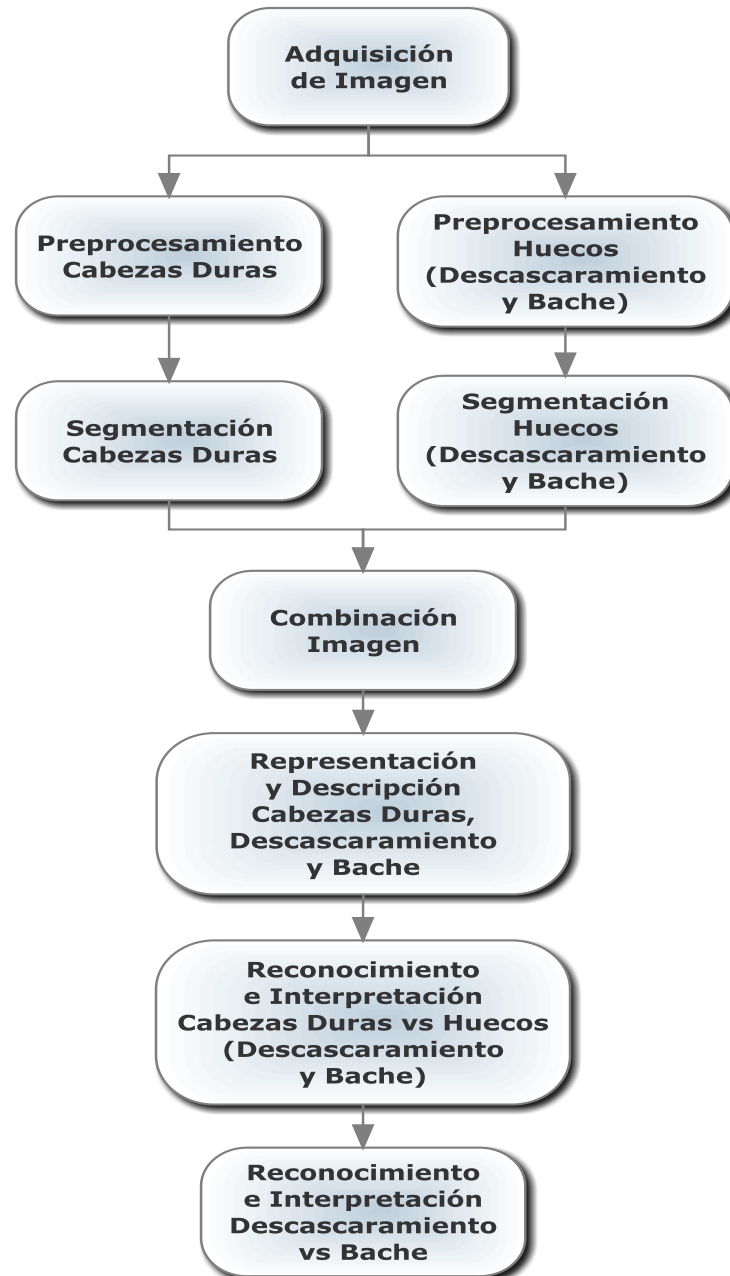
En primer lugar, se analizaron visualmente las imágenes captadas, y se dedujo que las imágenes de flexible al estar constituido de materiales pétreos y ligantes bituminosos, su color se centra en una amplia tonalidad de grises. Además, los materiales granulares expuestos son reflejados con mayor luminosidad por el desgaste natural. Por consiguiente las imágenes de pavimento flexible se asemejan al ruido impulsivo o sal y pimienta, evidenciando intensidades irregulares en la imagen.

Respecto a la falla tipo cabezas duras, la característica más notable es que el material granular expuesto en la superficie del pavimento presenta principalmente formas circulares y en algunos casos formas de diamante y formas rectangulares.

En cuanto a las fallas tipo descascaramiento y bache, se resalta una mayor tonalidad oscura en los bordes de la cavidad irregular cerrada y profunda, en consecuencia de la fricción producida entre las llantas del tráfico vehicular, el borde de la falla y el material de la carpeta asfáltica [10] [11] [12] [13] [14] [15].

Por las anteriores características notables en las imágenes captadas con los tres tipos de fallas y las etapas del procesamiento de imágenes, se plantea el diagrama de procesos de los algoritmos para el PDI (Figura 17).

**Figura 17.** Diagrama del proceso propuesto



## 6.2 HISTOGRAMA DE LAS IMÁGENES A ESCALA DE GRISES

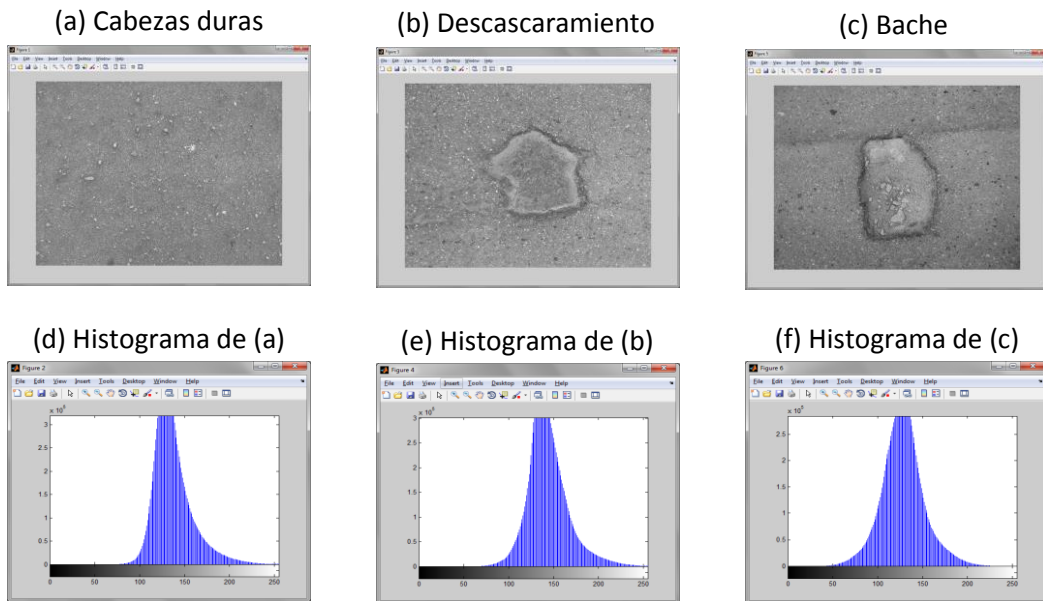
El histograma de una imagen es una función discreta que representa el número de píxeles en la imagen en función de los niveles de intensidad  $g$ . La probabilidad  $P(g)$  de ocurrencia de un determinado nivel  $g$  se define como [17]:

$$P(g) = \frac{N(g)}{M} \quad (6.1)$$

Donde  $M$  es el número de píxeles en la imagen y  $N(g)$  es el número de píxeles en el nivel de intensidad  $g$ . Como en cualquier distribución de probabilidad todos los valores de  $P(g)$  son menores o iguales que 1 y la suma de todos los valores de  $P(g)$  es 1.

Entonces, se procede a determinar la concentración de las zonas claras y oscuras, y a realizar una comparación de histogramas de los tres tipos de falla. La Figura 18 muestra un ejemplo de cada falla con su respectivo histograma.

**Figura 18.** Fallas de tipo desprendimiento con su respectivo histograma



El histograma de la Figura 18 (a), (b) y (c) muestra que no hay una diferenciación marcada entre las zonas claras y oscuras en la imagen, y en su defecto una tendencia de concentración media de gris. Por lo anterior, se procede a realizar el acondicionamiento para las fallas de tipo descascaramiento y bache.

## 6.3 ACONDICIONAMIENTO DE LAS IMÁGENES CON FALLAS TIPO DESCASCARAMIENTO Y BACHE (*POTHOLE* O HUECOS)

### 6.3.1 Suavizado de la imagen

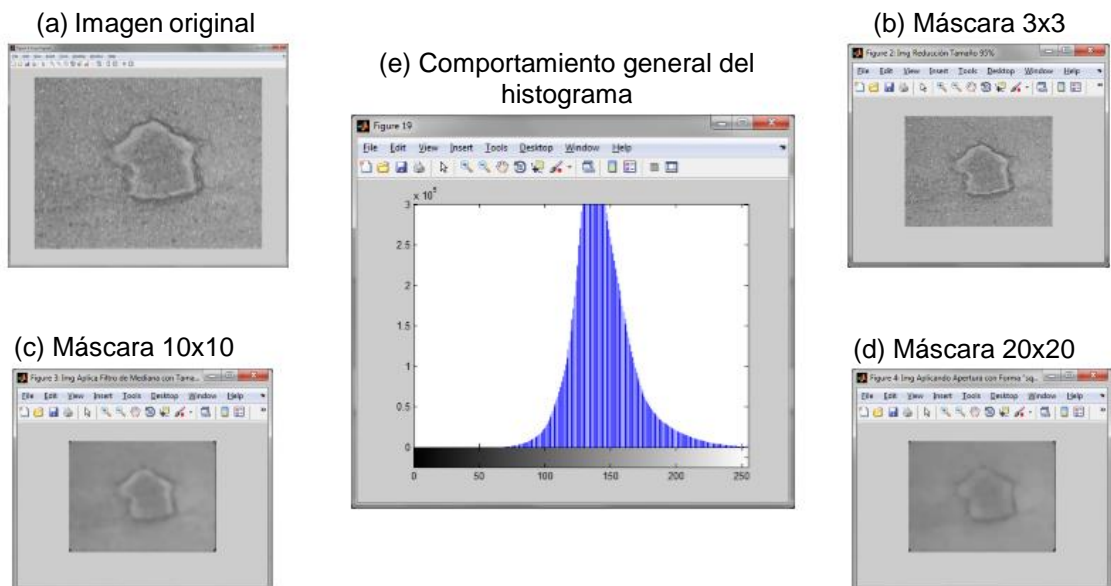
El filtro mediana opera mediante la mediana  $M$  de un conjunto de valores ordenados ascendentemente, tal que la mitad de los valores del conjunto son menores que  $M$  y la mitad de los valores son mayores que  $M$  [17]. El funcionamiento depende del número de filas y columnas asignadas a una máscara de evaluación. Matlab asigna por defecto una máscara de  $3 \times 3$  píxeles o se puede asignar un tamaño de máscara personalizado [16].

Con la finalidad de mejorar la imagen, se aplica el filtro de la mediana clasificado como filtro espacial no lineal, que permite remover el ruido de sal y pimienta, en comparación a otros filtros espaciales que presentan el problema de la degradación de puntos, líneas y bordes de los objetos de la imagen [15].

Para reducir el ruido de sal y pimienta, se aplica el filtro de mediana con máscaras de tamaño  $3 \times 3$ ,  $10 \times 10$  y  $20 \times 20$ . Se selecciona la máscara de  $3 \times 3$  porque es eficiente y causa menor alteración en el resultado de la imagen (Figura 19 (b)).

En general, el histograma de las imágenes filtradas con los tres tamaños de máscaras, muestra que la distribución de grises continúa con la misma tendencia concentrada en la zona media (Figura 19).

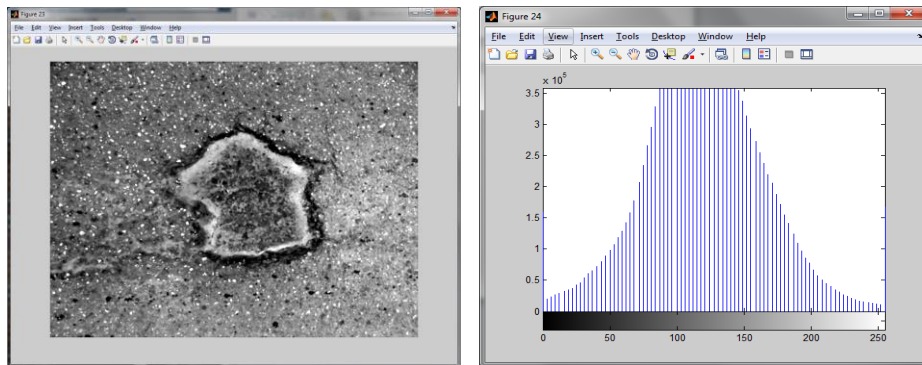
**Figura 19.** Filtro mediana y tendencia general del histograma



### 6.3.2 Contraste de la imagen

En general, un histograma con la distribución de los niveles de gris concentrados en determinada zona presenta un contraste muy bajo, mientras que un histograma con una amplia distribución de los niveles de gris tiene un alto contraste [17]. Por lo anterior se procede a realizar un ajuste de contraste como se muestra en la Figura 20, donde se aprecia la expansión del histograma.

**Figura 20.** Ajuste de contraste de la imagen



El ajuste de contraste, evidencia que no hay uniformidad en la iluminación de la imagen (Figura 20), debido a que las imágenes son captadas a una altura aproximada de 1.6 metros con cámara de escaneo por área sin un sistema de iluminación artificial. Por otra parte también se debe considerar que algunas imágenes presentan otros elementos como ruido por sombras y manchas.

### 6.3.3 Corrección de iluminación (homogeneización) de la imagen [18]

Ramírez, S. (2012) en su trabajo “detección de grietas en la cinta asfáltica mediante análisis de imágenes”, propone un método para corregir la iluminación de la imagen. El método se basa en mejorar la distribución del histograma y calcular la tendencia de los niveles de gris de los píxeles, para esto se usa dicha información y compensar la falta de iluminación en la imagen y posteriormente aplicar suma de imágenes para tratar de recuperar información que pudo perderse.

El primer paso es aplicar una transformación logarítmica con el fin de ampliar el rango de nivel de gris y aclarar la misma. Una transformación logarítmica se define con la siguiente ecuación:

$$s = c \log(1 + r) \quad (6.2)$$

Donde  $c$  es una constante,  $r$  es el valor del píxel de entrada y  $s$  el valor resultante de la transformación. El resultado es el aumento en el nivel de gris y expansión en el rango del histograma de la imagen.

La rectificación de la iluminación de la imagen se realiza mediante la sustracción de las variaciones de brillo de la imagen original. Para determinar estas variaciones se calcula el promedio de intensidad de los píxeles en cada columna.

Considerando la imagen una matriz de  $M \times N$ , se calcula el promedio de los elementos de cada columna, el resultado es un vector  $V$  de  $1 \times N$  que contiene la tendencia del nivel de intensidad de los píxeles de las columnas 1 hasta  $N$ .

La tendencia de los niveles de gris se utiliza para calcular una función que aproxime el comportamiento del fondo de la imagen. La función utilizada debe ser una ecuación matemática que describa el conjunto de datos y que sea mínimamente influenciada por el ruido, por tal motivo se realizó un ajuste de curvas con los promedios obtenidos. Para ello se utilizó una suma Gaussiana con 6 términos que está dada por la ecuación:

$$G(x) = \sum_{i=1}^6 a_i e^{-\left(\frac{x-b_i}{c_i}\right)^2} \quad (6.3)$$

Donde  $a$  es la amplitud,  $b$  es el centro de gravedad y  $c$  está relacionado con la anchura del pico.

El resultado del ajuste de curva es la función  $G(x)$ , que es la función que evalúa el vector  $V$ , cuyo tamaño es de  $1 \times N$  y es denominada “función de fondo” que aproxima el comportamiento de las variaciones de brillo del fondo de la imagen. La función de fondo se utiliza con el fin de nivelar la intensidad de los píxeles en la imagen. La sustracción se realizó mediante una resta de imágenes que equivale a restar la función de fondo de cada vector renglón de la imagen.

Después de rectificar la iluminación de la imagen se utilizó la transformada Wavelet por ventanas o “tiles” con el fin de minimizar la influencia de la textura y detalles ajenos para el realce de la imagen. Un “tile” es una sub-imagen con un tamaño establecido.

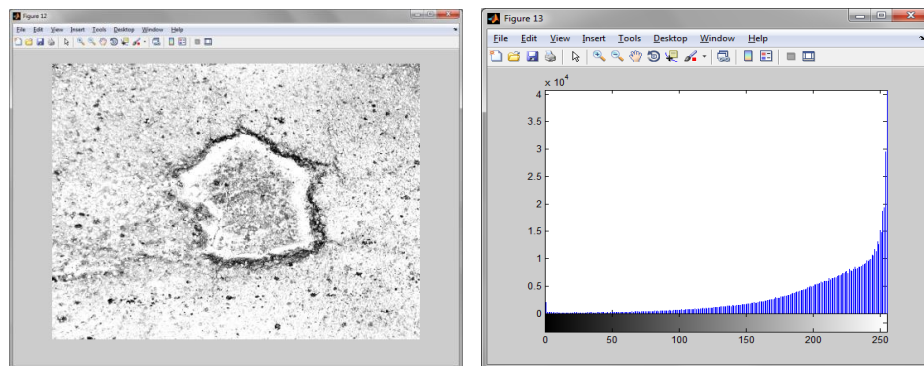
La transformada Wavelet discreta de dos dimensiones utiliza un conjunto de filtros discretos paso-bajo  $p(n)$  y paso-alto  $q(n)$  que se implementan a cada “tile” de la imagen.

Por ende, para una imagen original  $c_0(x, y)$  se calcula primero entre las filas de la imagen y los filtros  $p(n)$  y  $q(n)$  resultando dos imágenes, en cada una de ellas, se calcula la correlación con los filtros  $p(n)$  y  $q(n)$  en dirección horizontal, lo que resulta

en cuatro imágenes, una aproximación  $c_i(x,y)$  y los detalles horizontal, vertical y diagonal.

Finalmente, la imagen resultado de aplicar la transformada Wavelet (imagen con iluminación nivelada), se suma con ella misma para obtener una imagen que contiene píxeles con valor de intensidad mayor a 255. El siguiente paso es ajustar los valores de intensidad de la imagen a un rango de 0 a 255 [18]. La Figura 21 muestra la corrección de iluminación en la imagen.

**Figura 21.** Corrección de iluminación de la imagen y su respectivo histograma



#### 6.4 ACONDICIONAMIENTO DE LAS IMÁGENES CON FALLAS TIPO CABEZAS DURAS

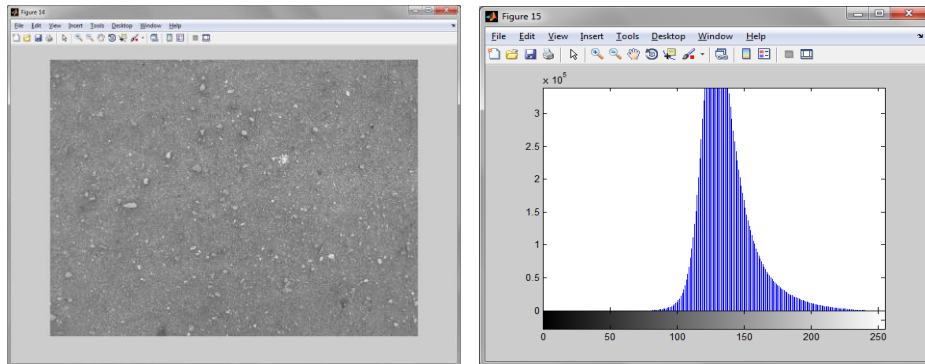
Como se menciona en el numeral 6.1, la característica más notable de la falla tipo cabezas duras es la exposición del material granular en la superficie del pavimento, que se asemeja al ruido de sal y pimienta, evidenciando intensidades irregulares en la imagen.

Cervera, N. et al. (2010), en su trabajo “*A simple algorithm for measuring particle size distributions on an uneven background from TEM images*” propuso detectar y medir nanopartículas de imágenes TEM con presencia de un fondo irregular, el algoritmo que propone consiste en segmentar la imagen por el método de umbralización Otsu y lo aplica de forma local dividiendo la imagen en ventanas o “*tiles*”. Cada ventana obtiene la diferencia de intensidad para hallar un umbral local óptimo y separar las partículas del fondo de la imagen [9].

Por lo anterior y evidenciando el ruido en las imágenes con falla de tipo cabezas duras, es necesario hacer una expansión del histograma de las imágenes para

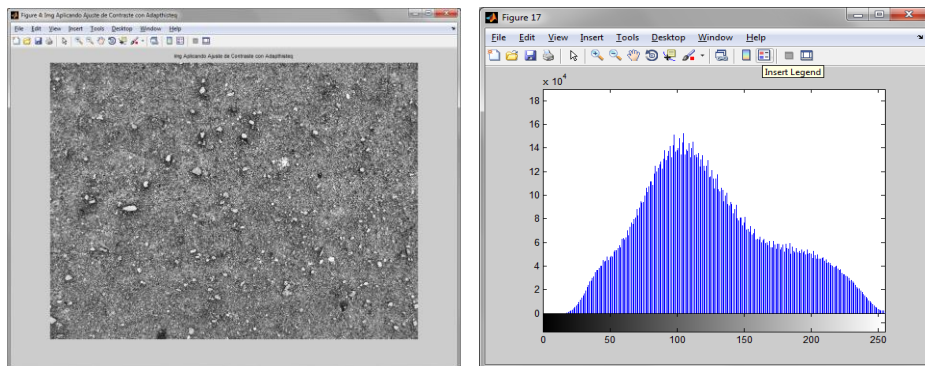
incrementar los detalles de la imagen y mejorar el contraste. Por tanto, se procede a suavizar la imagen con filtro mediana aplicando ventanas de  $3 \times 3$  píxeles con el fin de minimizar el ruido que presente el material granular expuesto en la superficie del pavimento. La Figura 22 muestra la aplicación del filtro mediana con ventana de  $3 \times 3$  y el respectivo histograma.

**Figura 22.** Falla tipo cabezas duras con filtro mediana y su respectivo histograma



Posteriormente, se hace uso de la ecualización adaptativa del histograma con contraste limitado (*CLAHE*) para mejorar el contraste a nivel local y global. La ecualización consiste en dividir la imagen en regiones pequeñas llamadas ventanas o “*tiles*”, para este caso la imagen original es dividida en 8 ventanas en la vertical y en la horizontal. Finalmente se combinan las ventanas vecinas usando una interpolación bilineal para eliminar las fronteras inducidas artificialmente. La Figura 23 muestra el ajuste de contraste realizado con ecualización adaptativa del histograma.

**Figura 23.** Falla tipo cabezas duras con ecualización adaptativa



## 7. SEGMENTACIÓN

La segmentación es el proceso donde se extrae de la imagen cierta información subyacente para su posterior análisis. Está basada en dos principios fundamentales: discontinuidad orientada a bordes y similitud orientada a regiones, en términos generales, una región es un área de la imagen en la que sus píxeles poseen propiedades similares de intensidad, color, etc.; mientras que un borde es una línea que separa dos regiones de diferentes propiedades [17].

En general, la segmentación subdivide una imagen en sus partes constituyentes u objetos, el nivel al que se lleva a cabo esta subdivisión depende del problema a resolver y debe detenerse cuando los objetos de interés hayan sido aislados. Es una de las tareas más complejas en el PDI, debido a que ésta etapa determina el éxito o fracaso del análisis [14].

### 7.1 PROCESO DE SEGMENTACIÓN PARA LAS FALLAS DE TIPO DESCASCARAMIENTO Y BACHE (POTHOLE O HUECOS)

Las técnicas clásicas de segmentación de imagen como detección de bordes, regiones o umbralización, son útiles cuando en las imágenes el objeto y el fondo son uniformes, y la presencia de ruido y otros elementos no son relevantes. La complejidad se incrementa cuando es necesario interpretar los objetos segmentados y dar conectividad o eliminar los falsos objetos segmentados [21] [22].

La solución propuesta para nuestro proyecto consiste en utilizar la denominada segmentación por contornos activos, ésta técnica es más robusta frente a la presencia de ruido y otros elementos no deseados en la imagen, aunque requiere más recurso de cómputo y más tiempo de cálculo.

#### 7.1.1 Contorno Activo

La segmentación por contorno activo extrae los contornos de los objetos de interés basado en un modelo de curva inicial llamado *snake* (serpiente, máscara o curva inicial) que se ajusta dinámicamente aplicando fuerzas energéticas, es decir, un *snake* se define como una curva que minimiza la energía, guiada por fuerzas o energías restrictivas externas e influenciada por fuerzas o energías de la imagen como líneas, bordes o regiones [21] [22] [23] [24] [25] [26].

Las fuerzas o energía de la imagen empujan el *snake* hacia características de la imagen como líneas, bordes o regiones subjetivas, mientras que las fuerzas restrictivas externas añaden información para hacer que el *snake* se vaya hacia el mínimo local deseado. El *snake* también posee una serie de fuerzas internas que sirven para imponer restricciones de suavidad, es decir, para regular la selección de los objetos a segmentar.

El *snake* se representa como una curva paramétrica que evoluciona en búsqueda de los contornos de los objetos presentes en la imagen mediante la minimización de un funcional de energía, tal como se expresa en la ecuación (7.1) [21] [22].

$$r(s) = (x(s), y(s)), \text{ con } s \in [0, 1] \quad (7.1)$$

Dependiendo de la variación de  $s$  entre cero y uno va recorriendo el contorno. Su funcional de energía se describe como:

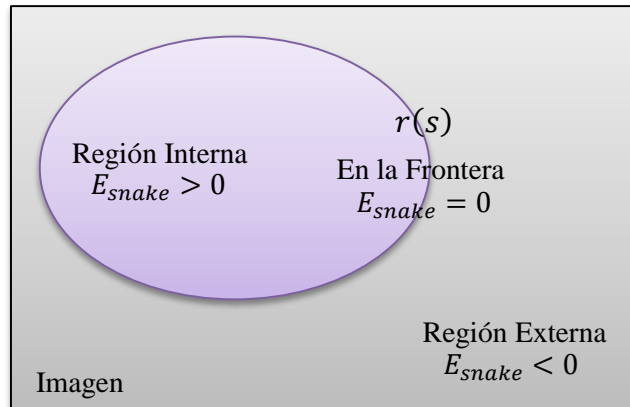
$$E_{snake}(r) = \int_0^1 E_{int}(r(s))ds + \int_0^1 E_{ext}(r(s)) \quad (7.2)$$

Donde  $E_{int}$  representa la energía interna del *snake*, y  $E_{ext}$  la fuerza restrictiva externa que atrae la curva o *snake* hacia el contorno de los objetos presentes en la imagen.

Como se menciona anteriormente, la energía utilizada para hallar los objetos presentes en la imagen puede estar representada en líneas, bordes o regiones. Para nuestro proyecto utilizamos el método Chan-Vese que utiliza las regiones de la imagen para calcular la energía.


En su trabajo, Chan-Vese [26] calcula o minimiza la función de energía ( $E_{snake}$ ) requerida en una región, dando como solución que de manera iterativa encuentra la frontera o borde de los objetos en la imagen cuando su función de energía se hace cero, es decir, la función de energía es igual para ambas regiones tanto interna como externa ( $E_{snake} = 0$ ). Así mismo el funcional de energía en la región interna es mayor que cero ( $E_{snake} > 0$ ) y el funcional de energía en la región externa es menor que cero ( $E_{snake} < 0$ ). La Figura 24 muestra el funcionamiento del método Chan-Vese.

**Figura 24.** Representación gráfica del método Chan-Vese



Como se mencionó, una de las desventajas del contorno activo es que requiere más recurso de cómputo y más tiempo de cálculo, con el fin de minimizar el recurso de cómputo y el tiempo de cálculo, se redimensionó el tamaño de la imagen en un 94% para obtener una imagen de 200 x 266 píxeles como entrada a la segmentación por contorno activo. La Figura 25 muestra la imagen redimensionada reduciendo el tamaño en un 94%.

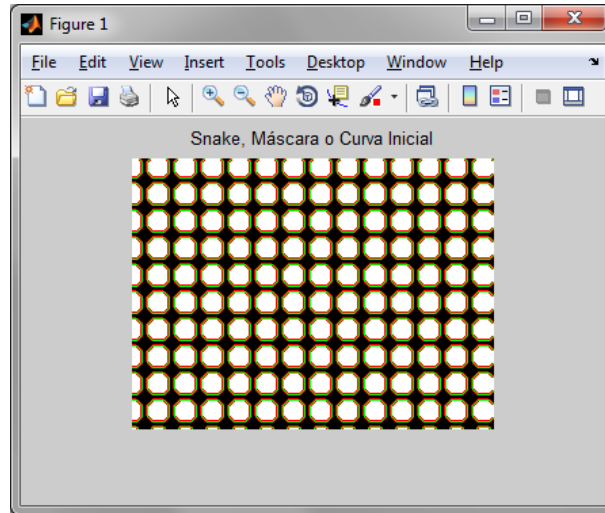
**Figura 25.** Imagen reducción de tamaño de 94%



Para nuestro proyecto se utiliza una máscara inicial compuesta de circunferencias de radio 9, distribuidos en el tamaño de la imagen para buscar las regiones de mayor

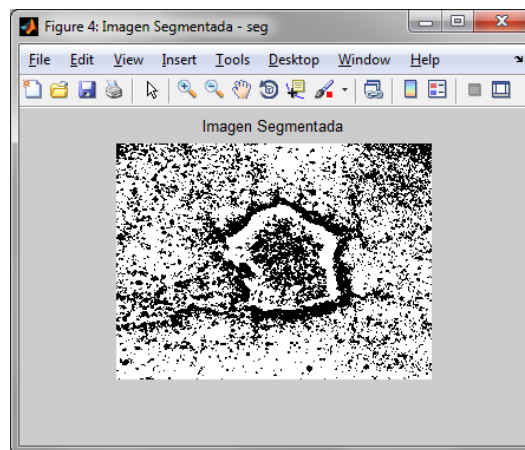
intensidad en la imagen que representa el borde del *pothole* o hueco (fallas descascaramiento o bache). La Figura 26 muestra la máscara inicial utilizada.

**Figura 26.** Snake, Máscara o Curva Inicial



El resultado de la segmentación por contorno activo es una imagen binaria que representa las regiones de mayor intensidad. Sin embargo acompañada del borde del hueco se encuentra ruido proveniente de manchas u otros objetos presentes en el pavimento, como lo muestra la Figura 27.

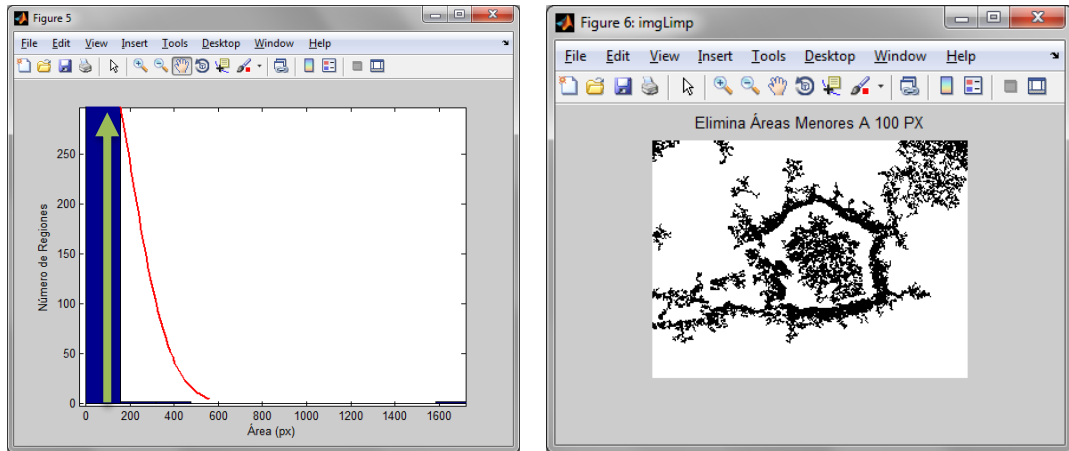
**Figura 27.** Resultado de aplicar segmentación por contorno activo



### 7.1.2 Eliminación de ruido pos-segmentación

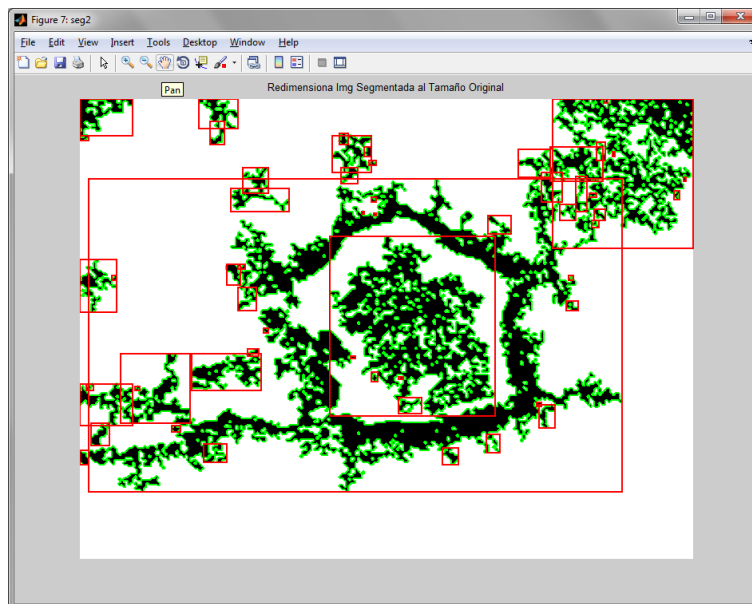
Para minimizar el ruido presente en la imagen, se evalúa el tamaño de las regiones sementadas. Se evidencia una mayor concentración de regiones con áreas menores a 200 píxeles. Se toma como referencia áreas menores o iguales a 100 píxeles para eliminar las regiones de la imagen como lo muestra la Figura 28.

**Figura 28.** Selección y eliminación de regiones menores o iguales a 100 píxeles



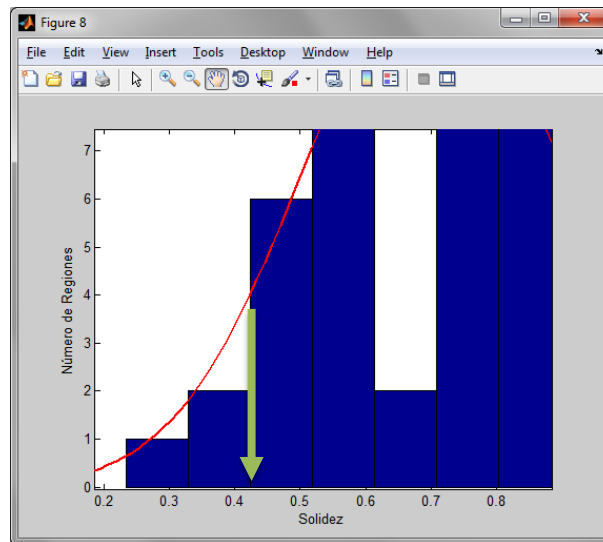
Se redimensiona la imagen al tamaño original de 3456 x 4608 píxeles (Figura 29).

**Figura 29.** Redimensión de la imagen a tamaño de 3456 x 4608 píxeles

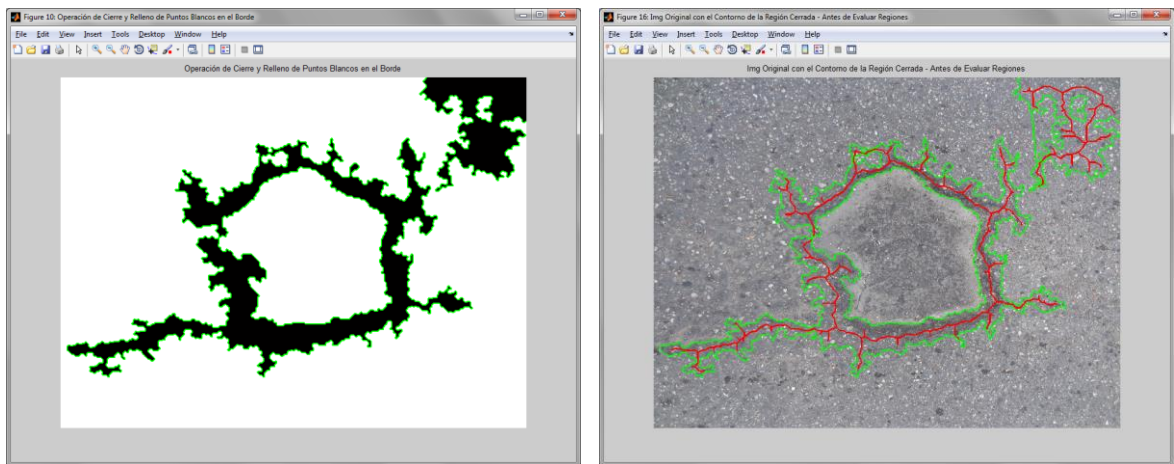


La solidez es un parámetro que representa la proporción de píxeles presentes en una región [27]. Para nuestro trabajo se seleccionaron las regiones con solidez menor o igual a 0,42 (Solidez  $\leq$  0,42), como resultado de evaluar la solidez de las regiones presentes en la imagen mediante el análisis estadístico descriptivo (Figura 30 y Figura 31).

**Figura 30.** Evaluación de Solidez  $\leq$  0,42

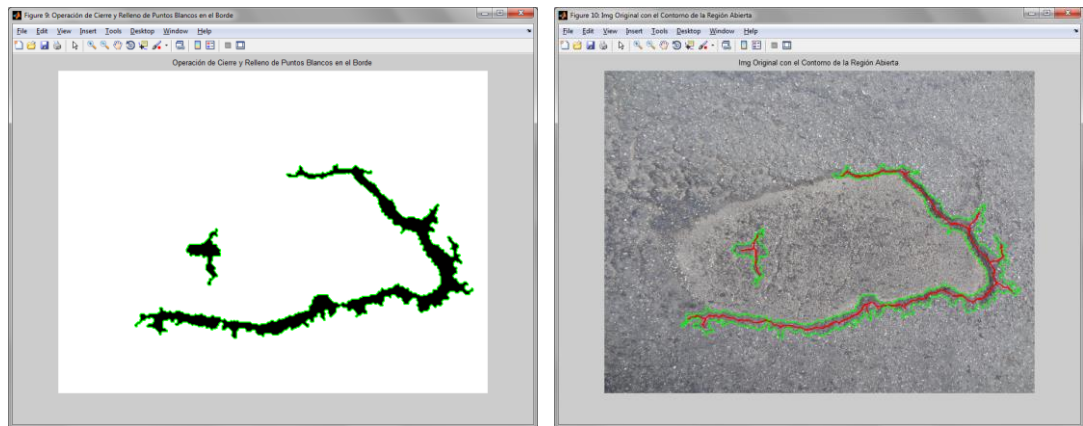


**Figura 31.** Resultado Solidez  $\leq$  0,42



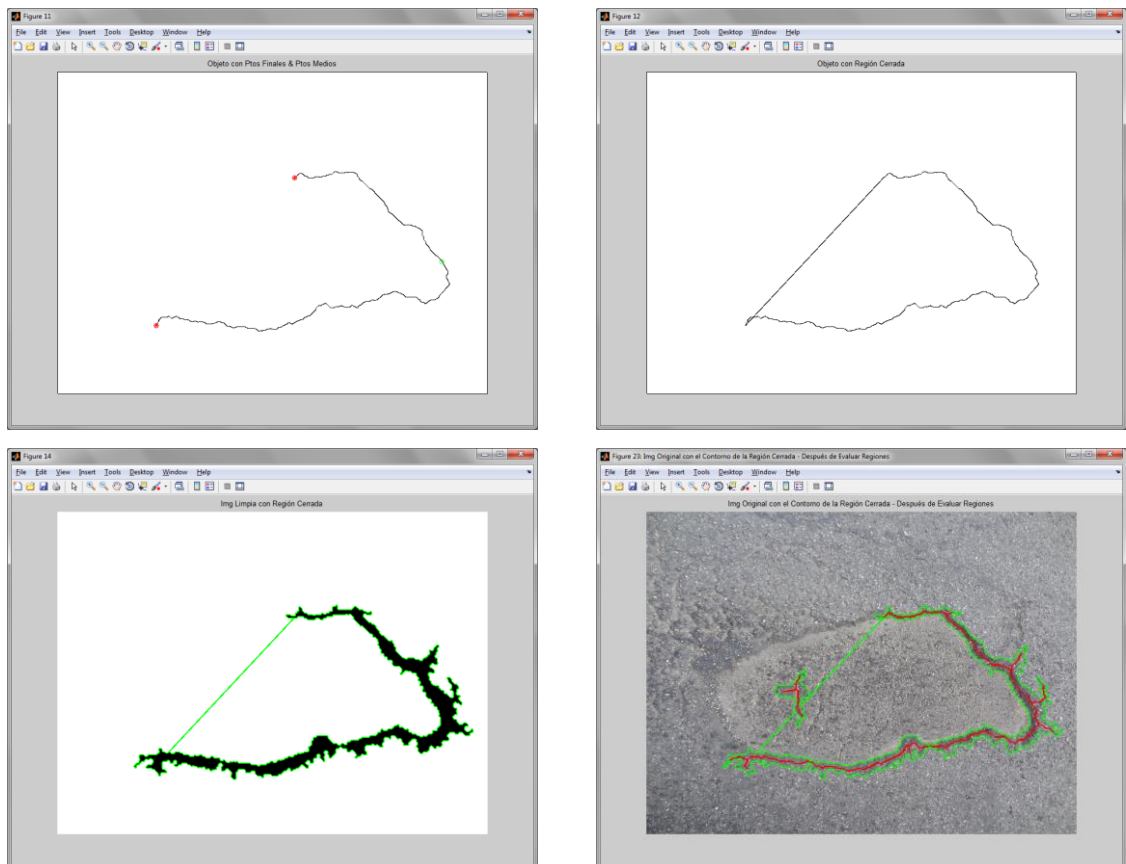
Algunas de las fallas presentan falencia en la continuidad de su borde, dejando regiones abiertas, donde la región segmentada carece de una parte importante del borde de la falla como lo muestra la Figura 32.

**Figura 32.** Borde demarcado por una región abierta



Para los casos en que la región segmentada no encierra completamente el borde de la falla (Figura 32), se realiza una búsqueda de los puntos extremos para cerrar la región con una línea recta como lo muestra la Figura 33.

**Figura 33.** Cerrar región con puntos extremos




Finalmente, se verifica que las regiones seleccionadas correspondan al borde que rodea las fallas de tipo descascaramiento o bache. Para tal fin se calcula  $RegQ$  (ecuación 7.3) que representa el valor absoluto de la diferencia entre la media de intensidad de gris de la región interna y la media de intensidad de gris de la región de borde en la imagen homogenizada tal como lo muestra la Figura 34.

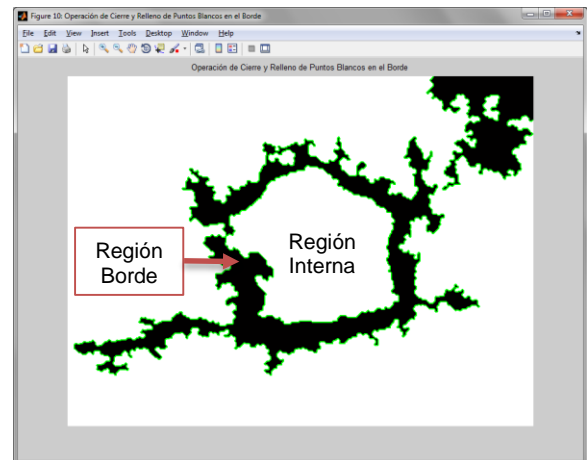
$$RegQ = |RegInterna - RegBorde| \quad (7.3)$$

**Figura 34.** Verificación de regiones

(a) Imagen homogenizada donde se evalúa la media de intensidad de gris, tanto de la región interna como de la región de borde.

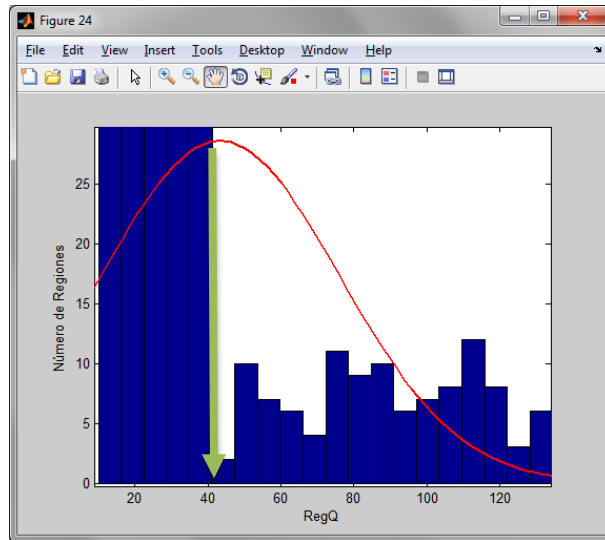


(b) Imagen binaria de la cual se extrae la región interna y la región de borde para calcular el  $RegQ$ .



Para que la región evaluada se tenga en cuenta su  $RegQ$  debe ser mayor o igual a 40 ( $RegQ \geq 40$ ), valor calculado de una muestra de 376 regiones, de las cuales 110 regiones representaban efectivamente el borde de las fallas tipo descascaramiento y bache con un  $RegQ > 40$  como lo muestra la Figura 35.

**Figura 35.**  $RegQ$  calculado para evaluar regiones

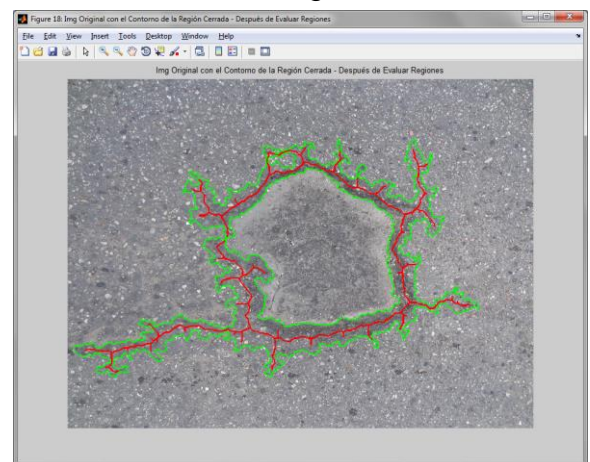
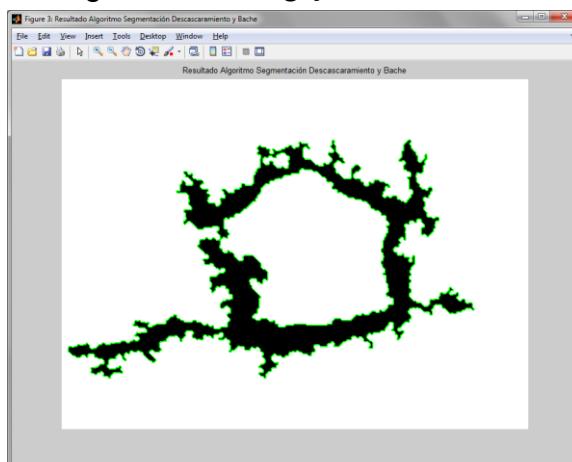


El resultado de evaluar regiones es obtener regiones que representen el borde de las fallas de tipo descascaramiento y/o bache, descartando el mayor ruido posible (Figura 36).

**Figura 36.** Resultado de la verificación de regiones con  $RegQ \geq 40$

(a) Imagen binaria de la verificación de regiones con  $RegQ \geq 40$ .

(b) Representación contorno imagen binaria sobre imagen a color.



## 7.2 PROCESO DE SEGMENTACIÓN PARA LAS FALLAS DE TIPO CABEZAS DURAS

### 7.2.1 Umbralización

La umbralización es una técnica de segmentación ampliamente utilizada en el procesamiento digital de imágenes. Se emplea cuando hay una clara diferencia entre los objetos a extraer respecto al fondo de la escena. Los principios que rigen son la similitud entre los píxeles pertenecientes a un objeto y sus diferencias respecto al resto. Por tanto, la escena debe caracterizarse por un fondo uniforme y por objetos parecidos [29].

Al aplicar la umbralización a una imagen, la imagen resultante es binaria; etiquetando con '1' los píxeles correspondientes al objeto y con '0' aquellos que son del fondo. Para la umbralización se aplica la siguiente expresión:

$$g(x,y) = \begin{cases} 1 & f(x,y) > T \\ 0 & f(x,y) \leq T \end{cases} \quad (7.4)$$

Donde  $f(x,y)$  es la función que retorna el nivel de gris del píxel  $(x,y)$ ,  $g(x,y)$  será la función de la imagen binarizada y  $T$  es el umbral.

### 7.2.2 Algoritmo de segmentación

Dado que la falla tipo cabezas duras no está presente en la mayoría de catálogos de inspección de pavimentos, y adicionalmente fallas similares a este tipo de deterioro han sido poco estudiadas; se realizó una revisión de la literatura en otros temas de investigación con similar problemática. Para este caso se encontró una técnica basada en el enfoque de umbralización adaptativa, que consiste en hacer uso de valores de umbral local que cambian con las coordenadas espaciales. Este método permite hacer la detección y caracterización con mayor precisión que otros métodos que hacen uso de un umbral global.

Los pasos del algoritmo implementado son:

1. División de la imagen original en  $36 \times 36$  subimágenes ("tiles").
2. Umbralizar cada subimagen. La salida de este procedimiento es una imagen binaria.
3. Aplicar la apertura (dilatación más erosión) con un tamaño de kernel 8.


- Combinar y analizar las subimágenes procesadas. En la imagen binaria resultante se restringen las partículas cuyo diámetro esté entre 25 píxeles y 110 píxeles lo que equivale a 1/2 pulgada y 2,2 pulgadas respectivamente. Este intervalo fue fijado atendiendo la recomendación del experto en inspección de pavimentos y el ajuste ensayo prueba error sobre las imágenes. Posteriormente, se restringen las que tengan excentricidad entre 0 y 0,96. Este intervalo fue fijado por ensayo prueba error, al observar que al restringir la redondez se eliminaba ruido como hojas de árboles o de otro tipo de objetos presentes en la imagen. Por último, los bordes de las regiones son representados en la imagen original para evaluar los resultados (Figura 37).

El algoritmo anterior aplica a cada subimagen la umbralización cuyo resultado contiene dos clases de píxeles (los que pertenecen a los objetos y los que pertenecen al fondo), y determina el umbral óptimo automáticamente mediante el "método Otsu" para minimizar la varianza intracase (variabilidad entre los individuos de una misma clase) de los píxeles de los objetos y el fondo.

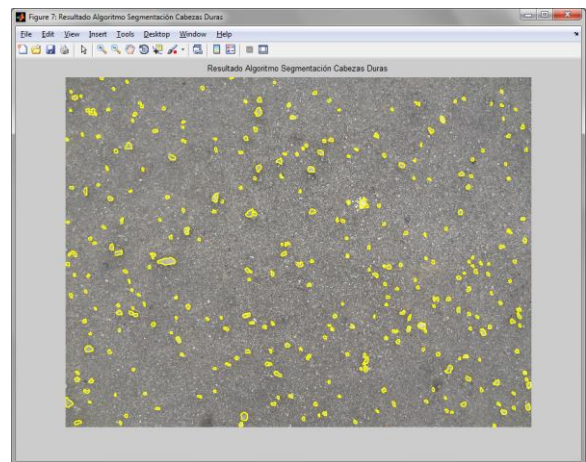
El operador de apertura (erosión seguida por dilatación) se utiliza para suavizar los bordes por eliminación de pequeñas protuberancias, romper estrechos istmos y eliminar regiones que son más pequeñas que el tamaño del elemento estructurante [9]. Cuando se selecciona el tamaño del *kernel* es posible establecer un tamaño mínimo de regiones a ser detectadas. En este caso se hace uso de un elemento estructurante de tamaño 8, porque se aproxima al tamaño de las regiones que representan las fallas de tipo cabezas duras. Además en los ensayos de prueba y error el tamaño del elemento estructurante selecciona las regiones de interés.

**Figura 37.** Resultado segmentación algoritmo Cabezas Duras

(a) Imagen binaria de la segmentación algoritmo cabezas duras.



(b) Representación contorno imagen binaria sobre imagen a color.

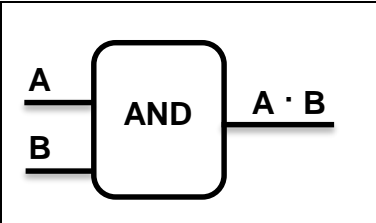


### 7.3 COMBINACIÓN ALGORITMOS DE SEGMENTACIÓN

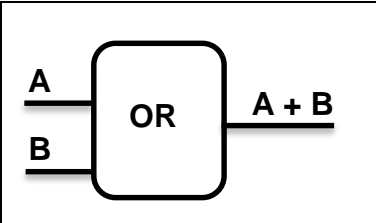
Una vez segmentada la imagen tanto en el algoritmo de segmentación para las fallas de tipo descascaramiento y bache (capítulo 7.1), como en el algoritmo de segmentación para las fallas de tipo cabezas duras (capítulo 7.2), se procede a combinar las dos imágenes resultantes para tener una única imagen segmentada que representa las regiones de interés a clasificar.

La combinación de las imágenes de segmentación se realiza aplicando los operadores lógicos “AND” y “OR” [27], que en el álgebra booleana se representa como lo muestra la Tabla 3 y la Tabla 4:

**Tabla 3.** Operador lógico “AND” del álgebra booleana

	Entradas		Salida
	A	B	A AND B
	0	0	0
	0	1	0
	1	0	0
1	1	1	

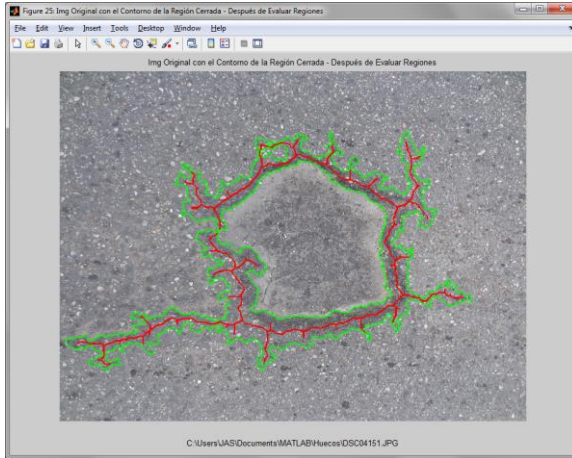
**Tabla 4.** Operador lógico “OR” del álgebra booleana

	Entradas		Salida
	A	B	A OR B
	0	0	0
	0	1	1
	1	0	1
1	1	1	


La Figura 38 es un ejemplo de la combinación de los algoritmos de segmentación, representado en color amarillo, rojo y verde el contorno de las imágenes binarias sobre la imagen a color procesada.

**Figura 38.** Combinación algoritmos de segmentación


(a) Resultado algoritmo de segmentación para las fallas de tipo descascaramiento y bache.



(b) Resultado algoritmo de segmentación para las fallas de tipo cabezas duras.



(c) Resultado combinación algoritmos de segmentación.



## 8. DESCRIPCIÓN

Con la segmentación se ha llegado al punto de subdividir la imagen en sus partes constituyentes u objetos. La descripción de las regiones es parte del proceso de transformación de los datos de píxel en bruto de los objetos a una forma adecuada para ser posteriormente tratados por computadora. Consiste en extraer rasgos con alguna información cuantitativa de interés o que sean fundamentales para diferenciar una clase de objetos de otra.

González en su libro “tratamiento digital de imágenes” menciona que la representación de una región se puede hacer en términos de características externas (contorno) cuando el interés principal es describir la forma de los contornos (el reconocimiento posterior se basa en cómo es la forma de los objetos detectados), y características internas (los píxeles que comprenden la región) cuando el interés principal es describir las propiedades de la región (el reconocimiento de los objetos detectados se basa en las propiedades de reflectividad como color, textura, etc.). En el estudio se tuvo en cuenta las características internas porque las regiones a describir son de naturaleza amorfa.

### 8.1 CARACTERÍSTICAS INTERNAS

#### 8.1.1 Escalares simples

Son descriptores que pueden ser calculados de forma muy sencilla sobre las regiones, pero que pueden ser suficiente en muchas tareas de descripción siempre que las formas a describir no sean excesivamente complejas. En general, estos descriptores no pueden usarse para la reconstrucción de la región.

Los descriptores usados para la descripción y caracterización de las regiones de interés son:

**Área:** Se define como el número de píxeles contenido en su contorno. En la representación habitual de una imagen en matriz, el cálculo de área se reduce a una cuenta de píxeles.

**Diámetro:** Se refiere al escalar que especifica el diámetro de un círculo con la misma área que la región, se expresa como:

$$Diámetro = \sqrt{\frac{4 \text{ Área}}{\pi}} \quad (8.1)$$

**Descriptores de niveles de gris:** Son descriptores que se calculan con el nivel de gris de los píxeles, pero que no requieren de cálculos complejos:

- **Máximo y mínimo Nivel de gris:** Consiste en el máximo y mínimo valor de los valores en escala de grises que están asociados con los píxeles de una región.

**Máximo y mínimo de las bandas RGB:** Consiste en el máximo y mínimo valor de los valores de cada una de las bandas de las que está compuesta una imagen RGB y que están asociados con los píxeles de una región.

### 8.1.2 Textura

Un método importante para la descripción de regiones consiste en cuantificar su contenido de textura. Aunque no existe una definición formal de la textura, si proporciona intuitivamente medidas de propiedades como la suavidad, la rugosidad, la regularidad, entre otras.

Conceptualmente la característica principal de una textura es la repetición de un patrón. Los tres métodos principales más utilizados en el procesamiento de imágenes para describir la textura de una región son los estadísticos, estructurales y espectrales [31].

El modelo estructural se refiere a las primitivas o patrón repetitivo y se describe en términos de reglas; este método es el mejor para describir las texturas donde hay mucha regularidad en la colocación de elementos primitivos y la textura está proyectada en alta resolución.

Las técnicas espectrales se basan en las propiedades del espectro de Fourier y se utilizan para detectar la periodicidad global de una imagen mediante la identificación de picos estrechos de alta energía del espectro. Las técnicas espectrales se utilizan primordialmente para detectar la periodicidad global de una imagen [14].

El método estadístico usualmente describe la textura por reglas estadísticas de la distribución y relación de niveles de grises; las soluciones estadísticas proporcionan características de textura como la suavidad, la rugosidad y la granulosidad. El método estadístico puede describir mejor las variaciones que se presentan en texturas que no pueden ser descritas de un modo satisfactorio mediante las formas.

Por lo anterior y dado que la textura tratada en este proyecto no exhibe un patrón base uniforme y con repetición periódica, se optó por el método estadístico.

## 8.2 MÉTODO ESTADÍSTICO DE TEXTURA

El método estadístico permite describir la textura y consiste en utilizar momentos del histograma de nivel de gris de una imagen o región. Sea  $z$  una variable aleatoria que indica la intensidad de una imagen discreta y sea  $p(z_i)$ ,  $i = 1, 2, \dots, L$  el correspondiente histograma, donde  $L$  es el número de niveles de intensidad diferentes. El momento  $n$  –ésimo de  $z$  respecto a la media es [14]:

$$\mu_n(z) = \sum_{i=0}^{L-1} (z_i - m)^n p(z_i) \quad (8.2)$$

Siendo  $m$  el valor medio de  $z$  (la intensidad media):

$$m = \sum_{i=0}^{L-1} z_i p(z_i) \quad (8.3)$$

## 8.3 ESTADÍSTICOS DE PRIMER ORDEN

Por primer orden se entienden las estadísticas en las que se ven involucrados píxeles simples en contraposición a las estadísticas de más de un píxel (pares, tripletes, etc.). Proporcionan información relativa a la distribución de niveles de grises en la imagen.

Sea  $x$  una variable aleatoria que representa el nivel de gris en la imagen  $f(x)$ , la fracción de píxeles con nivel de gris  $x$ ,  $P(x)$  será el histograma de la imagen definido por:

$$P(x) = \frac{\text{número de píxeles con nivel de gris } x}{\text{número de píxeles en la imagen}} \quad (8.4)$$

### Nivel de gris medio:

Sea  $N_g$  el número de posibles niveles de grises en la imagen, se definen los siguientes estadísticos de primer orden:

$$m_1 = E[x^1] = \sum_{x=0}^{N_g-1} x^1 P(x) \quad i = 1, 2, \dots \quad (8.5)$$

Donde  $m_1$  es el nivel de gris medio.

Los niveles de gris medio tenidos en cuenta para este proyecto son: nivel de gris medio de las regiones en el modelo RGB, nivel de gris medio de la banda roja de las regiones, nivel de gris medio de la banda azul de las regiones, nivel de gris medio de la banda verde de las regiones.

## 8.4 ESTADÍSTICOS DE SEGUNDO ORDEN


A diferencia de los estadísticos de primer orden que consideran solamente la distribución de intensidades, los de segundo orden consideran también las posiciones de píxeles que tienen iguales, o casi iguales, valores de intensidad. [14]

Los estadísticos de segundo orden miden las dependencias espaciales que caracterizan a una textura [32].

Para capturar las dependencias espaciales de los valores de niveles de gris, que contribuyen a la percepción de las texturas presentes en una imagen, se define una estructura 2D llamada matriz de coocurrencia.

La matriz de coocurrencias  $C[i, j]$  se define especificando una dirección de desplazamiento  $d = (d_i, d_j)$  y contando todos los pares de píxeles separados por  $d$  y que tienen valores de gris  $i$  y  $j$  [14]. El valor de  $C[i, j]$  indica cuantas veces el valor  $i$  ocurre con el valor  $j$  en alguna relación espacial indicada. El vector  $d$  da la relación espacial que especifica el desplazamiento entre el píxel que tiene valor  $i$  y el píxel que tiene valor  $j$ .  $d_i$  es un desplazamiento en filas (hacia abajo) y  $d_j$  es un desplazamiento en columnas (a la derecha) [31].

**Figura 39.** Tres diferentes matrices de coocurrencia para una imagen 4x4 I en tono de grises:  $C(0,1)$ ,  $C(1,0)$ ,  $C(1,1)$  [31].



Una importante variación de la matriz estándar de coocurrencia de tonos grises y de que se desprende los descriptores de segundo orden utilizados en este proyecto es la matriz de coocurrencia de tonos grises normalizada  $N_d$  definida por [31]:

$$N_d(i, j) = \frac{C_d(i, j)}{\sum_i \sum_j C_d(i, j)} \quad (8.6)$$

$N_d$ , normaliza los valores de coocurrencia para que estén entre cero y uno y les permite ser considerados como probabilidades en una matriz grande.

Con la captura de propiedades de textura realizada por la matriz de coocurrencia de tonos grises normalizada ya se puede proceder a calcular características numéricas que puedan ser utilizadas para representar la textura de una forma más compacta. Haralick (1973) propuso una variedad de medidas de textura basadas en la matriz de coocurrencia de tonos grises normalizada denominadas características texturales. Las siguientes son características estándar derivables de una matriz de coocurrencia de tonos grises normalizada [31]:

$$\text{Energía} = \sum_i \sum_j N_d^2(i, j) \quad (8.7)$$

$$\text{Entropía} = - \sum_i \sum_j N_d(i, j) \log_2 N_d(i, j) \quad (8.8)$$

$$\text{Contraste} = \sum_i \sum_j (i - j)^2 N_d(i, j) \quad (8.9)$$

$$\text{Homogeneidad} = \sum_i \sum_j \frac{N_d(i, j)}{1 + |i - j|} \quad (8.10)$$

$$\text{Correlación} = \frac{\sum_i \sum_j (i - \mu_i)(j - \mu_j) N_d(i, j)}{\sigma_i \sigma_j} \quad (8.11)$$

Donde  $\mu_i, \mu_j$  son las medias y  $\sigma_i, \sigma_j$  son las desviaciones estándar de la fila y columna (i y j respectivamente).

Sumas de  $N_d(i)$  y  $N_d(j)$  definidas por:

$$N_d(i) = \sum_j N_d(i, j) \quad (8.12)$$


$$N_d(j) = \sum_i N_d(i, j) \quad (8.13)$$

Por último el vector de desplazamiento  $d$  puede ser escogido utilizando el test estadístico  $X^2$  utilizado por Zucker y Terzopoulos que consiste en seleccionar el valor(es) de  $d$  que tiene la mayor estructura; que es maximizar el valor:

$$X^2(d) = \left( \sum_i \sum_j \frac{N_d^2(i, j)}{N_d(i) N_d(j)} - 1 \right) \quad (8.14)$$

Se experimentó con valores de  $d=1$  y  $d=2$ , y con direcciones  $0^\circ, 45^\circ, 90^\circ$  y  $135^\circ$ .

**Figura 40.** Relación dirección y distancia, píxel de interés y su vecindad [27].



En la Tabla 5 y en la

Tabla 6 se observan los valores de estructura de algunos patrones de textura.

**Tabla 5.** Valores de estructura para  $d=1$

	$0^\circ [0\ 1]$	$45^\circ [-1\ 1]$	$90^\circ [-1\ 0]$	$135^\circ [-1\ -1]$
<b>Bache</b>	-1	-1	2.2510	-1
<b>Descascaramiento</b>	-1	-1	2.3184	-1
<b>Cabezas duras</b>	-1	-1	0.8732	-1

**Tabla 6.** Valores de estructura para  $d=2$

	$0^\circ [0\ 2]$	$45^\circ [-2\ 2]$	$90^\circ [-2\ 0]$	$135^\circ [-2\ -2]$
<b>Bache</b>	-1	-1	0.9001	-1
<b>Descascaramiento</b>	-1	-1	1.0094	-1
<b>Cabezas duras</b>	-1	-1	0.4887	-1

La mayor estructura fue observada en  $d=1$  y en la dirección de  $90^\circ [-1\ 0]$  en pruebas realizadas con patrones de los tres tipos de fallas.


#### 8.4.1 Cálculo de estadísticos de segundo orden

Para el cálculo numérico de los estadísticos de segundo orden de textura utilizados en este proyecto se tuvo en cuenta la optimización hecha por Eizan Miyamoto y Thomas Merryman en “*Fast Calculation Of Haralick Texture Features*” [33] al algoritmo de Haralick de obtención de medidas texturales. Esta optimización consiste en hacer modificaciones a los dos pasos constituyentes del algoritmo de

Haralick: la construcción de la matriz de coocurrencia de tonos grises normalizada mediante un algoritmo de bloqueo recursivo junto al cálculo de las propiedades estadísticas para reducir el tiempo de ejecución en esta etapa; la segunda parte es el cálculo de características que es optimizada por la puesta en uso de información sobre los datos (combinación de características y del cálculo de propiedades estadísticas necesarias) que se están trabajando con eliminación de algunas redundancias en el código para reducir el tiempo de cómputo y los accesos a memoria. Igualmente en las etapas anteriormente descritas se utilizan prácticas estándar de optimización de código tales como reemplazo escalar y desarrollando los ciclos *for* para la reducción del tiempo de ejecución.


Lo novedoso del método utilizado, es el algoritmo de bloqueo, que consiste en dividir una imagen  $N \times N$  en imágenes más pequeñas de dimensiones  $B \times B$ . Estas subimágenes son divididas a su vez en imágenes más pequeñas y así recursivamente hasta que se haya alcanzado el caso base.

**Figura 41.** Algoritmo de bloqueo [33]




La coocurrencia es calculada para cada una de las imágenes más pequeñas y a continuación son combinadas para formar la coocurrencia de la imagen entera. Un ejemplo sencillo de ilustración es el examen de vecinos horizontal de distancia  $d$ . En este caso primero se calcula las coocurrencias de las primeras imágenes más pequeñas creadas durante el bloqueo. Luego este paso se itera hasta que el caso base haya sido alcanzado. El caso base ocurre cuando las subimágenes son de dimensión  $1 \times 1$ , un píxel individual. Se representa como se muestra en la Figura 42.

**Figura 42.** Construcción de matriz de coocurrencia para  $d=1$ : Imagen original (caso base) (a) empieza por examinar cada uno de sus pares de vecinos: Parte (b) muestra la etapa incremental que ocurre cuando los píxeles vecinos esbozados en (a) son examinados. Parte(c) muestra el resultado final de la matriz de coocurrencia para  $d=1$  [33].




En este paso se examinan los píxeles de la imagen y actualiza la matriz de coocurrencia acordemente. Luego el siguiente paso es la comparación horizontal de los vecinos (*children*) que consiste en comparar los bloques niños con otros bloques niños en la misma fila. Esta comparación se realiza de la misma forma entre los bloques más pequeños hasta alcanzar el caso base.

**Figura 43.** Esta es una ilustración del paso recursivo de comparación de niños. Parte (a) Muestra el padre de un niño oscuro(c). Este niño de (a) se utilizará para calcular coocurrencias con cada uno de los niños oscuros mostrados en la parte (b). Parte (d) es un niño en particular de (b) que es para ser comparado con (c). Parte (c) y (d) entonces repiten este proceso hasta que el caso base se ha alcanzado [33].



El proceso para el cálculo de los vecinos verticales es similar, excepto que se examinan bloques que se encuentran en las mismas columnas de la imagen. En ambos casos se examina cada subimagen una vez. Los parámetros para el bloqueo son encontrados utilizando una búsqueda que es específica de la plataforma. La Figura 44 ilustra el mecanismo de bloqueo en un caso más general.

**Figura 44.** La parte (a) muestra todos los hermanos que deben ser comparados en el caso de 135 grados. Parte (b) muestra los hermanos que deben ser comparados en el caso de 90 grados. Parte (c) muestra los hermanos que deben ser comparados en el caso de 45 grados. Parte (d) muestra los hermanos que deben ser comparados en el caso de 0 grados [33].



## 9. CLASIFICACIÓN

### 9.1 VECTOR DE CARACTERÍSTICAS

Cada característica extraída determina la propiedad comparativa que hace distinto a un objeto de otro. Estas medidas que son las entradas para la clasificación, son usadas en forma de un vector de características, en donde  $l$  representa el número de características  $Z_i$ , con  $i = 1, 2, 3, \dots, l$

$$z = \begin{pmatrix} z_1 \\ z_2 \\ z_3 \\ \cdot \\ \cdot \\ \cdot \\ z_l \end{pmatrix} \quad (9.1)$$

Cada uno de estos vectores identifica únicamente a un solo patrón (objeto). [39]. En este proyecto se optó por crear vectores de características con diferentes propiedades, en este caso color, textura y descriptores simples de región para el reconocimiento del tipo de fallas a clasificar en este caso descascaramiento, baches y cabezas duras.

### 9.2 SELECCIÓN DE DESCRIPTORES RELEVANTES

En reconocimiento de patrones el conjunto de variables empleadas para medir las observaciones se conoce como *espacio de características* [34], el cual es un espacio abstracto donde cada ejemplo (patrón) es representado como un punto en un espacio n-dimensional. La *dimensión* de este espacio es determinada por la cantidad de variables que describen los patrones.

Cuando la dimensión del espacio de características es alta, se debe procurar remover la redundancia de datos o información irrelevante para reducir la dimensión; algunas de las principales razones para hacerlo son: facilitar el análisis de datos, obtener mayor precisión en las tareas de clasificación, disminución del costo computacional, hacer clara cualquier estructura oculta (si existiera), obtener una representación gráfica que facilite la interpretación de datos, entre otras [34].

El objetivo de la reducción de dimensión consiste en encontrar la representación sobre alguna variedad en un sistema coordenado, que permita obtener una

representación alterna y compacta con la menor dimensión posible. El problema de la reducción de la dimensionalidad se formaliza de la siguiente forma, para cada muestra  $i$  determinar una selección o transformación de características:

$$x_{ij} \rightarrow y_{ik} \quad j = 1, \dots, n; k = 1, \dots, l \quad l < n \quad (9.2)$$

Tal que transforma los datos originales  $x \in \mathbb{R}^n$  en los de la salida  $y \in \mathbb{R}^l$  de menor dimensionalidad,  $l < n$ . Existen dos aproximaciones generalmente utilizadas para afrontar este problema:

**Selección de atributos:** En este caso los datos resultantes son extraídos desde el conjunto original formando un subconjunto del original. El gran problema de este enfoque es que se hace necesario determinar cuáles son los más significativos respecto a las clases del conjunto de datos.

**Transformación de atributos:** En este caso se genera una transformación de los datos de forma que los resultantes pueden ser ordenados sistemáticamente en cuanto a su relevancia. Existen técnicas que simplifican este problema al generar conjuntos significativos en el número deseado,  $l$ , o bien conjuntos sistemáticamente ordenados en cuanto a relevancia [30].

Una de las distinciones claves de los dos enfoques radica en sus resultados. Asumiendo que se tiene cuatro características  $F_1, F_2, F_3, F_4$ , si ambos enfoques resultan en 2 características, las 2 *seleccionadas* son un subconjunto de 4 características originales (por ejemplo  $F_1, F_3$ ), pero las 2 características extraídas es alguna combinación de 4 características originales (ejemplo  $F'_1 = \sum a_i F_i$  y  $F'_2 = \sum b_i F_i$  donde  $a_i, b_i$  son algunas constantes) [40].

La aproximación elegida para selección de los descriptores relevantes en este proyecto es selección de atributos (selección de características) debido a que la reducción de dimensionalidad se puede implementar con relativa facilidad y porque su marco conceptual es de sencilla comprensión.

### 9.2.1 Selección de características:

Los beneficios de la selección de atributos son múltiples: ayuda a mejorar el aprendizaje en cuanto a exactitud de predicción, comprensibilidad, eficiencia de aprendizaje, modelos compactos, y efectiva recolección de datos.

El objetivo de la selección de características es remover características irrelevantes y/o redundantes y retener únicamente las características relevantes. El término de características redundantes se refiere a un tipo de características irrelevantes. La distinción es que una característica redundante implica la presencia de otra característica. La estructura de un sistema de selección de características está

formado por cuatro componentes básicos: entrada, búsqueda, evaluación, salida [40].

**Entrada:** Son los datos que pueden ser de naturaleza supervisada, no supervisada o semisupervisada. En relación a la solución del problema en cuestión, la entrada son datos de naturaleza supervisada. Estos datos son normalizados antes de ingresar al módulo de búsqueda. Para tal fin se utiliza el escalamiento *softmax*, dado que es una forma de reducir la influencia de los valores atípicos sin removerlos del *dataset*. Lo anterior es de utilidad cuando se poseen datos atípicos que se desean incluir en el *dataset* al tiempo que se conserva la significancia de los datos dentro de una desviación estándar de la media.

Consiste de dos pasos:

$$y = \frac{x_{ik} - \bar{x}_{ik}}{r\sigma_k} \quad (9.3)$$

$$\hat{x}_{ik} = \frac{1}{\exp(-y)} \quad (9.4)$$

Donde  $x_{ik}$  son los valores a normalizar,  $\bar{x}_k$  es la media de los valores de la  $k$ -ésima característica,  $\sigma_k$  es la desviación estándar,  $y$  es el grado de escalamiento de cada valor, proporcional a la distancia que ese valor tenga hacia la media y  $\hat{x}_{ik}$  es el nuevo valor normalizado.  $r$  es un factor definido por el usuario; el valor utilizado de  $r$  en el presente proyecto fue 0.5.

La transformación realizada es básicamente una función de aplastamiento o compresión que limita los datos entre el rango [0,1] [39].

**Búsqueda:** En este componente se utilizan estrategias de búsqueda para seleccionar las características. Existen diferentes modelos de selección de características (kohavi & John, 1997) tales como *wrapper*, *filter*, o *embedded*. El modelo escogido fue *filter* porque se basa en medidas sobre las propiedades intrínsecas de los datos por lo que es independiente del clasificador. Igualmente porque es el más aplicado cuando el propósito de la selección de características va más allá de la mejora del rendimiento de aprendizaje (por ejemplo precisión de la clasificación).

La búsqueda de características relevantes se puede realizar de dos maneras:

**Clasificación de características (ranking features):** Las características se clasifican de acuerdo a las propiedades intrínsecas de los datos de modo que las  $k$  primeras características pueden ser escogidas de acuerdo a la necesidad o un umbral dado.

**Selección de subconjuntos:** Un subconjunto de características se selecciona a partir del conjunto completo de características, y no hay diferencias relevantes entre las características en el subconjunto seleccionado [40].

La selección de subconjuntos puede llevarse a cabo de varias maneras. En la Tabla 7 se describen algunos métodos de selección de subconjuntos.

**Tabla 7.** Métodos de selección de subconjuntos [41].

Método	Propiedades	Comentarios
Búsqueda exhaustiva	Evalúa todas $\binom{d}{m}$ posibles subconjuntos	Garantiza encontrar el subconjunto óptimo; No factible para incluso moderadamente grandes valores de m y d
Mejores características individuales	Evalúa todas las m características individualmente ;selecciona las m mejores características individuales	Computacionalmente simple; No es probable que conduzca a un subconjunto optimo
Selección secuencial hacia adelante(SFS)	Selecciona la mejor característica individual y agrega una característica a la vez que en combinación con las características seleccionadas maximiza la función criterio	Una vez que se retiene una característica, no puede ser descartada; computacionalmente atractiva ya que seleccionando un subconjunto de tamaño 2, examina únicamente (d-1) posibles subconjuntos
Selección secuencial hacia atrás	Comienza con todas las d características y elimina sucesivamente una característica a la vez	Una vez una característica es descartada, esta no puede volver de nuevo al subconjunto óptimo; requiere más calculo que la selección secuencial hacia adelante(SFS)

Según *Statistical Pattern Recognition: A Review de Anil K Jain* el método de búsqueda exhaustiva es uno de los muy pocos métodos de selección de características que garantiza un subconjunto óptimo. Dado que este método tiene la gran desventaja de que el número de subconjuntos crece combinatoriamente,

haciéndolo un método inadecuado inclusive para moderados valores de  $m$  y  $d$ , se ha optado por hacer una combinación de la búsqueda de características por ranking y la búsqueda de características por selección de subconjuntos.

Por lo anterior se hace uso de medidas que cuantifican el poder discriminatorio en la clase de características individuales y de combinaciones de características

Para realizar el *ranking* de características primero se reduce el número de características descartando las menos informativas, para esto se hizo uso del método *Scalar Feature Selection* que consiste en usar un criterio para cuantificar el poder de discriminación de clase individual de características, para tal fin se utilizó el criterio *Fisher's discriminant ratio (FDR)* que es comúnmente empleado para cuantificar el poder discriminatorio de características individuales entre dos clases equiprobables (es independiente del tipo de distribución de la clase).

$$FDR = \frac{(m_1 - m_2)^2}{(\sigma_1^2 - \sigma_2^2)} \quad (9.5)$$

Donde  $m_1$  y  $m_2$  son los respectivos valores medias y  $\sigma_1^2$  y  $\sigma_2^2$  las respectivas varianzas asociadas con los valores de una característica en dos clases [35].

Entre mayor sea el valor de FDR más informativa será la característica.

**Tabla 8.** Clasificación por valor FDR para el primer *dataset* (integrado por los patrones de la clase cabezas duras y la clase *pothole*)

NOMBRE CARACTERÍSTICA	VALOR FDR	ÍNDICE
Diametrocirculo	34,8808	18
Área	9,8600	17
minR	3,4665	22
minimaintensidad	3,4161	16
minG	3,4053	23
minB	3,3706	24
maxB	2,1141	21
maximaintensidad	1,9424	14
maxG	1,9322	20
maxR	1,8676	19
sum_varianza	1,6774	8
medida_correlacion2	1,6190	13
medida_correlacion1	1,2087	12
mediaG	1,1554	26

<b>NOMBRE CARACTERÍSTICA</b>	<b>VALOR FDR</b>	<b>ÍNDICE</b>
Mediaintensidad	1,0805	15
suma_media	1,0768	7
mediaB	0,9834	27
suma_cuadrados	0,9663	6
sum_entropia	0,9312	9
mediar	0,8301	25
Entropía	0,7970	2
Energía	0,4688	5
diferencia_entropia	0,1008	11
Correlacion	0,0988	1
Contraste	0,0905	3
diferencia_varianza	0,0874	10
Homogenidad	0,0838	4

**Tabla 9.** Clasificación por valor FDR para el segundo *dataset* (integrado por los patrones de la clase bache y la clase descascaramiento)

<b>NOMBRE CARACTERÍSTICA</b>	<b>VALOR FDR</b>	<b>ÍNDICE</b>
mediar	0,1390	23
maxB	0,0401	19
sum_varianza	0,0375	8
maxG	0,0336	18
Maximaintensidad	0,0333	14
Mediaintensidad	0,0327	15
suma_media	0,0324	7
suma_cuadrados	0,0320	6
minB	0,0303	22
maxR	0,0241	17
mediaG	0,0202	24
minG	0,0147	21
Minimaintensidad	0,0093	16
mediaB	0,0074	25
medida_correlacion2	0,0061	13
Contraste	0,0057	3
Homogenidad	0,0048	4
diferencia_entropia	0,0043	11
Correlacion	0,0037	1

NOMBRE CARACTERÍSTICA	VALOR FDR	ÍNDICE
diferencia_varianza	0,0034	10
Energía	0,0023	5
minR	0,0023	20
entropia	0,0008	2
medida_correlacion1	0,0006	12
sum_entropia	0,0001	9

Luego se procede a utilizar la correlación cruzada para tener en cuenta las correlaciones existentes entre las características, para ello primero se ordena los valores de FDR en orden descendente; el siguiente paso es dejar  $i_1$  ser el índice del mejor clasificado (número de característica dentro del *dataset*); a continuación se calcula las correlaciones cruzadas entre la primera característica clasificadas con cada una de las demás características.

El índice,  $i_2$ , de la segunda mejor característica, es calculado así:

$$i_2 = \max_j \{a_1 C_j - a_2 |\rho_{i_1, j}|\}, j \neq i_1 \quad (9.6)$$

$C_j$  es el valor de el criterio FDR para  $j$ th característica,  $\rho_{i_1, j}$  correlación cruzada entre la mejor característica ( $i_1$ ) y la característica  $j \neq i_1$ .  $a_1$  y  $a_2$  son parámetros definidos por el usuario.

$$i_k = \max_j \left\{ a_1 C_j - \frac{a_2}{k-1} \sum_{r=1}^{k-1} |\rho_{i_r, j}| \right\}, j \neq i_r, r = 1, 2, \dots, k-1 \quad (9.7)$$

Para  $k = 3, 4, \dots, m$ . Se puede observar que la correlación media con todas las características previamente consideradas, son tenidas en cuenta [35].

**Tabla 10.** Clasificación por valor FDR y teniendo en cuenta correlación cruzada para el primer *dataset*.

<b>NOMBRE CARACTERÍSTICA</b>	<b>ÍNDICE</b>
diametrocirculo	18
area	17
minR	22
minB	24
minimaintensidad	16
minG	23
maxB	21
maximaintensidad	14
maxG	20
maxR	19
medida_correlacion2	13
sum_varianza	8
medida_correlacion1	12
energia	5
mediaG	26
sum_entropia	9
mediaintensidad	15
suma_media	7
mediaB	27
diferencia_varianza	10
entropia	2
suma_cuadrados	6
homogenidad	4
mediaR	25
contraste	3
diferencia_entropia	11
correlacion	1

**Tabla 11.** Clasificación por valor FDR y teniendo en cuenta correlación cruzada para el segundo *dataset*.

<b>NOMBRE CARACTERÍSTICA</b>	<b>ÍNDICE</b>
mediaR	23
diferencia_varianza	10
contraste	3
minB	22
medida_correlacion2	13
energia	5
diferencia_entropia	11
homogenidad	4
entropia	2
medida_correlacion1	12
minG	21
correlacion	1
minimaintensidad	16
sum_entropia	9
sum_varianza	8
minR	20
suma_cuadrados	6
mediaintensidad	15
maxB	19
suma_media	7
mediaB	25
maximaintensidad	14
mediaG	24
maxG	18
maxR	17

Por último se procede a reducir el número de características escogiendo un número determinado de las mejores clasificadas, en este caso se escogieron las 7 mejores.

**Tabla 12.** Características de las mejores clasificadas en el primer *dataset* tenidas en cuenta para la búsqueda exhaustiva.

<b>NOMBRE CARACTERÍSTICAS SOBREVIVIENTES</b>	<b>ÍNDICE</b>
minimaintensidad	16
area	17
diametrocirculo	18
maxB	21
minR	22
minG	23
minB	24

**Tabla 13.** Características de las mejores clasificadas en el segundo *dataset* tenidas en cuenta para la búsqueda exhaustiva.

<b>NOMBRE CARACTERÍSTICAS SOBREVIVIENTES</b>	<b>ÍNDICE</b>
contraste	3
energia	5
diferencia_varianza	10
diferencia_entropia	11
medida_correlacion2	13
minB	22
mediaR	23

Después de reducir el número de características por descarte de las menos informativas, se tiene en cuenta las características que sobrevivieron en diferentes combinaciones con el fin de seleccionar la mejor combinación. Para ello es utilizado el método de búsqueda exhaustiva. A continuación se muestran los pasos del algoritmo [42]:

Dado un conjunto de datos establecido  $T_{all}$  con  $N_{all}$  patrones etiquetados constituidos con  $n$  características  $X = \{x_1, x_2, \dots, x_n\}$ . Un criterio de selección de características  $J_{texture}$  con un procedimiento de cálculo basado en un *dataset* de limitado tamaño  $T_{texture}$

1. Establecer  $j = 1$  (se inicializa contador del número de subconjunto de características )

2. Seleccionar un subconjunto de características  $X^j \subseteq X$  (con el número de elementos  $1 \leq N_{X^j} \leq n$ ).
3. Para un subconjunto de características seleccionado  $X^j$ , calcular un criterio de selección de características  $J_{texture}(X^j)$ .
4. Si  $j \leq 2^n$ , continúe desde el paso 2; de lo contrario, vaya al siguiente paso.
5. Se elige un subconjunto óptimo  $\hat{X}_{opt}$  con un máximo valor de el criterio de selección
 
$$J_{texture}(\hat{X}_{opt}) \geq J_{texture}(\hat{X}^j), j = 1, 2, \dots, 2^n$$

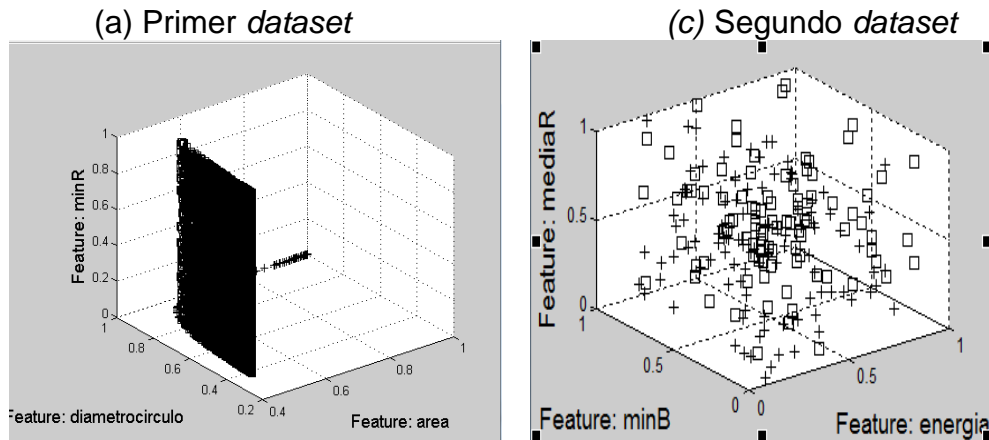
**Tabla 14.** Subconjunto óptimo seleccionado de características para el primer dataset

<b>NOMBRE DE LAS CARACTERÍSTICAS RESULTANTES DE LA BÚSQUEDA EXHAUSTIVA</b>	<b>ÍNDICE DE LAS MEJORES COMBINACIONES</b>
area	17
diametrocirculo	18
minR	22

**Tabla 15.** Subconjunto óptimo seleccionado de características para el segundo dataset

<b>CARACTERÍSTICAS RESULTANTES DE LA BÚSQUEDA EXHAUSTIVA</b>	<b>ÍNDICE DE LA MEJOR COMBINACIÓN</b>
energia	5
minB	22
mediaR	23

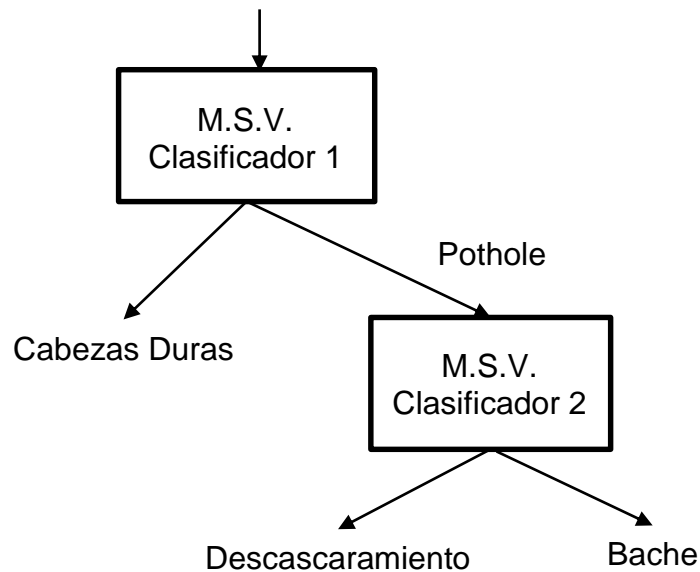
**Figura 45.** Gráfica de los patrones empleando el subconjunto óptimo seleccionado de características.



### 9.3 CLASIFICADOR

El diseño del clasificador se hace con base a un planteamiento de la solución pensado para discriminar en dos instancias (clasificación en cascada); la primera discrimina dos clases, clase cabezas duras y clase pothole; en la segunda instancia se discrimina entre la clase descascaramiento y la clase bache a partir de patrones previamente discriminados como pothole.

**Figura 46.** Esquema general de la solución



Para llevar a cabo la solución se propuso realizar una clasificación basada en máquinas de soporte vectorial, que se tratan de un conjunto de algoritmos que pertenecen a la familia de los clasificadores lineales puesto que inducen separadores lineales o hiperplanos en espacios de características de muy alta dimensionalidad con un sesgo inductivo muy particular [36].

Estas máquinas funcionan en dos fases: entrenamiento y decisión.

- a) Entrenamiento:** El objetivo del proceso de entrenamiento consiste en encontrar una función de decisión capaz de separar las dos clases. En el caso de que las clases sean no separables, los vectores se proyectan en un espacio de dimensión superior mediante el uso de funciones de transformación no lineales. En este caso, la función de decisión se sitúa en el hiperplano de esa dimensión [17].

El problema de optimización que la máquina de soporte vectorial necesita resolver es el mostrado en la ecuación (9.8) [37].


$$\min_{W,b,\xi} \frac{1}{2} W^T W + C \sum_{i=1}^n \xi_i \quad (9.8)$$

$$\text{Sujeto a: } (W^T \phi(x_i) + b) \geq 1 - \xi_i, \\ \xi_i \geq 0$$

Donde

- $(x_1, y_1), (x_2, 2) \dots (x_n, y_n)$  es el conjunto de entrenamiento
- $x_i$  es la representación vectorial de los ejemplos de entrenamiento
- $y_i$  la etiqueta que representa la clase a la que corresponde  $n$  la cantidad de individuos
- $W^T \phi(x_i) + b$  representa el hiperplano de separación
- $W$  es el vector de pesos
- $B$  es el bias.
- $\phi$  es la función kernel que permite llevar los datos a un espacio N-dimensional mayor en el cual puedan ser separables.
- $C$  es un parámetro positivo que especifica el usuario y que controla el equilibrio entre la complejidad de la máquina y el número de puntos no separables por un hiperplano
- $\xi_i$  se denomina variable de holgura, que mide la desviación de un punto  $x_i$  del punto de separación  $W^T \phi(x_i) + b$

**Figura 47.** Representación gráfica del modelo de optimización a resolver [37].



Existen cuatro *kernel* básicos [38]:

- Función kernel lineal:

$$K(x_i, x_j) = x_i^T x_j \quad (9.9)$$

- Función kernel polinomial:

$$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \quad \gamma > 0 \quad (9.10)$$

- Función de base radial gaussiana (RBF):

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \quad \gamma > 0 \quad (9.11)$$

- Función Sigmoidal:

$$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r) \quad (9.12)$$

Donde  $\gamma, r$  y  $d$  son parámetros del *kernel*.

Para la primera máquina de soporte vectorial se ingresa tanto para entrenamiento como para testeo los datos de las tres características seleccionadas, en este caso área, diámetro del círculo, y minR. Y para la segunda máquina de soporte vectorial energía, minB y mediaR.

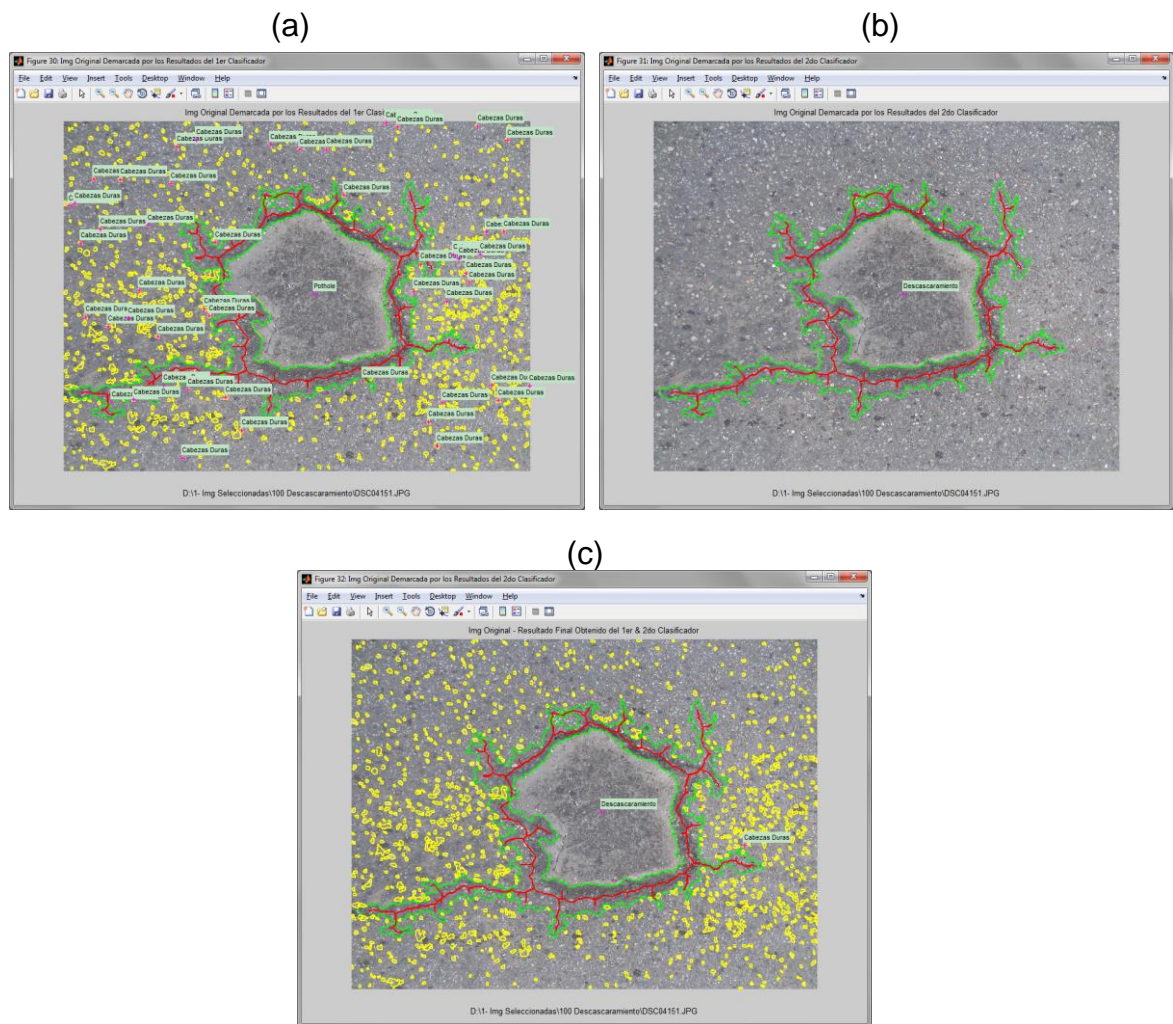
Para las dos máquinas de soporte vectorial implementadas se hicieron pruebas con cuatro *kernels*: lineal, cuadrático, polinomial y base radial

gaussiano con el fin de determinar cuál funciona mejor en la solución del problema planteado. Estas pruebas están descritas en el capítulo 10.

**b) Decisión:** Es una fase posterior a la de entrenamiento. Dado un nuevo vector  $x$ , se determina la clase a la que pertenece [17].

Para medir el rendimiento del clasificador es utilizada la medida de precisión (valores predictivos tanto positivos como negativos), descrita en el capítulo 10.

**Figura 48.** Ejemplo clasificación de fallas (a) clasificación entre cabezas duras y pothole (b) clasificación entre descascaramiento y bache (c) imagen combinada de los resultados del clasificador 1 y el clasificador 2.



## 10. ANÁLISIS DE RESULTADOS

Una vez procesadas las 300 imágenes, contempladas en 100 imágenes por cada tipo de falla (cabezas duras, descascaramiento y bache), se procede a evaluar el rendimiento de los algoritmos, calculando los índices de sensibilidad, especificidad, precisión, y el coeficiente de correlación de *Matthews*. [18] [19] .

### 10.1 PRUEBAS DE DETECCIÓN

En las pruebas de detección se calculan los índices de sensibilidad y especificidad, debido a que la sensibilidad permite medir la capacidad de la herramienta *software* para detectar los objetos segmentados correctamente (verdaderos positivos), y puede entenderse como la probabilidad de que el sistema detecte las fallas evaluadas que están presentes en la imagen.

Por otra parte, la especificidad nos permite medir la capacidad de la herramienta *software* para descartar objetos que no son de interés (verdaderos negativos), y puede entenderse como la probabilidad de que el sistema descarte correctamente objetos presentes en la imagen, que no representan las fallas evaluadas en éste trabajo.

La sensibilidad ( $S$ ) se define como la razón de verdaderos positivos y se calcula como el número de veces que la herramienta *software* interpretó correctamente los objetos seleccionados, dividido por el número total de objetos en la imagen, para ello se adiciona el concepto de falsos negativos que se calculan como el número de veces que erróneamente la herramienta *software* descartó los tipos de falla, como se define en la ecuación (10.1) [30]:

$$\% S = \frac{VP}{VP + FN} \times 100 \quad (10.1)$$

La especificidad ( $E$ ) se define como la razón de verdaderos negativos y se calcula como el número de veces que la herramienta *software* descartó correctamente objetos que no son falla, dividido por el total de objetos que no son falla y se encuentran presentes en la imagen, para el total de objetos que no son falla, se adiciona el concepto de falsos positivos que se calculan como el número de veces que la herramienta *software* interpretó erróneamente objetos como falla, tal como se define en la ecuación (10.2) [30].

$$\% E = \frac{VN}{VN + FP} \times 100 \quad (10.2)$$

Las ecuaciones (10.1) y (10.2) relaciona los siguientes indicadores: verdaderos positivos (VP), verdaderos negativos (VN), falsos positivos (FP) y falsos negativos (FN), que para el cálculo de los índices de sensibilidad y especificidad se definen en la Tabla 16, validados por inspección visual de los resultados obtenidos al procesar las 300 imágenes seleccionadas para éste trabajo.

**Tabla 16.** Descripción y resultados de los indicadores utilizados para sensibilidad y especificidad

<b>Indicador</b>	<b>Descripción</b>	<b>Valor Calculado</b>
<b>VP</b>	Fallas Detectadas	173036
<b>VN</b>	Objetos en la imagen que No son Falla y No se Detectaron como Falla	392854
<b>FN</b>	Objetos que No son Falla y Se Detectaron como Falla	55542
<b>FP</b>	Fallas No Detectadas	13802

$$\% S = \frac{173036}{173036 + 55542} \times 100 = 92,61$$

$$\% E = \frac{392854}{392854 + 13802} \times 100 = 87,61$$

La Tabla 17 muestra los resultados porcentuales de la sensibilidad y la especificidad para la detección de las fallas.

**Tabla 17.** Resultados sensibilidad y especificidad

<b>% Sensibilidad (S)</b>	<b>92,61</b>
<b>% Especificidad (E)</b>	<b>87,61</b>

De los resultados obtenidos, un 92,61 % de sensibilidad evidencia que la totalidad de las fallas no son detectadas, por diferentes factores como falta de iluminación uniforme, regiones descartadas por los parámetros seleccionados, entre otros; sin embargo también nos indica que por cada 100 fallas, aproximadamente 93 son detectadas correctamente.

Por otra parte, un 87,61 % de especificidad nos indica que por cada 10 objetos que no representen falla aproximadamente 9 son descartados correctamente, sin embargo también evidencia que una minoría es detectada erróneamente como sombras u otros objetos presentes en las imágenes que se asemejen a los tipos de fallas tratados en éste proyecto.

## **10.2 PRUEBAS DE CLASIFICACIÓN**

Durante el desarrollo de los clasificadores de fallas tipo desprendimiento implementados mediante la técnica de máquinas de soporte vectorial se realizaron pruebas para medir el rendimiento de los clasificadores, consistentes en variar el parámetro  $C$  de las SVM (*support vector machine*) y los parámetros libres de cada una de las funciones *kernel* y observar el comportamiento de algunas métricas de rendimiento de clasificación.

### **10.2.1 Métricas de rendimiento**

Las métricas tenidas en cuenta para las pruebas de clasificación en el presente proyecto son: sensibilidad, especificidad, valor predictivo positivo, valor predictivo negativo y coeficiente de correlación de *Mathews*.

La sensibilidad en la clasificación al igual que en detección se define como la razón de verdaderos positivos, en el presente proyecto fue calculado como el número de veces que la SVM ha clasificado correctamente la categoría considerada, dividido por el número total de veces que aparece dicha categoría. Para la primera SVM la categoría considerada fue la clase cabezas duras; para la segunda SVM la categoría considerada fue la clase bache.

La especificidad en clasificación al igual que en detección se define como la razón de verdaderos negativos; se calcula como el número de veces que la SVM ha clasificado correctamente la ausencia de la categoría seleccionada, dividido por el número de veces que aparece la ausencia de la categoría seleccionada. Para la primera SVM se consideró como ausencia de categoría seleccionada la clase pothole; para la segunda SVM se consideró como ausencia de la categoría seleccionada la clase descascaramiento.

El valor predictivo es también denominado precisión. Esta medida aplica tanto para la categoría considerada, como para la ausencia de la categoría seleccionada.

El PPV (valor predictivo positivo) se define como el número de veces que se ha clasificado correctamente la categoría considerada, dividido por el número total de veces que dicha categoría aparecía en los resultados.

El NPV (valor predictivo negativo) se define como el número de veces que se ha clasificado la ausencia de la categoría considerada, dividido por el número total de veces que dicha categoría no aparecía en los resultados.

$$\% PPV = \frac{VP}{VP + FP} \times 100 \quad (10.3)$$

$$\% NPV = \frac{VN}{FN + VN} \times 100 \quad (10.4)$$


El *Matthews correlation coefficient* (MCC) es una medida de la calidad de las clasificaciones binarias, se utiliza principalmente en clasificadores binarios.

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (10.5)$$

### 10.2.2 Validación

Las métricas de rendimiento utilizadas en el presente proyecto son medidas durante la ejecución del método de validación cruzada (*cross-validation*). La validación cruzada es un método de validación que es utilizado para evaluar el rendimiento de los clasificadores, consiste en que con un conjunto de datos de  $m$  muestras se procede a entrenar el clasificador con  $m - 1$  muestras, dejando una por fuera para evaluar la respuesta del clasificador. Este proceso se repite  $m$  veces dejando fuera una muestra diferente en cada caso. Lo anterior permite realizar una evaluación sistemática.

**Figura 49.** Ilustración método de validación cruzada: Validación cruzada de K iteraciones con  $K=4$ .



El número de muestras  $m$  utilizadas para realizar la validación cruzada en el presente proyecto es 10 debido a que con carácter general se suele considerar ese número para garantizar una estimación fiable del error de generalización.

Las  $m$  medidas de las métricas son promediadas en el método de validación cruzada. Mediante el método de validación cruzada y la variación de los parámetros libres se puede encontrar un buen rendimiento del clasificador. Para el caso del *kernel* lineal no hay un parámetro libre, pero se varía el parámetro  $C$  de la SVM en 0.1 en cada paso, iniciando en 0.1 y terminando en 1. Para el *kernel* cuadrático igualmente solo se varía  $C$  en las mismas proporciones. En el *kernel* polinomial se varía el parámetro  $C$  y el parámetro libre  $d$  de la función *kernel*, este último variando en 1 en cada paso, empezando en el valor de 1 y terminando en 5. Por último en el *kernel* de base radial gaussiano se varía  $C$  y el parámetro libre  $\gamma$  (gama) de la función *kernel*, este último variando en 0.05 en cada paso y empezando en el valor de 0.05 y terminando en 0.5.

El conjunto de datos para la primera máquina de soporte vectorial fue conformado con 41166 patrones pertenecientes a la clase cabezas duras y 209 patrones pertenecientes a la clase pothole; igualmente el conjunto de datos para la segunda máquina de soporte vectorial fue conformado con 96 patrones pertenecientes a la clase bache y 109 patrones pertenecientes a la clase descascaramiento. Estos patrones están conformados por los valores de las características seleccionadas con el método de selección de atributos.

### 10.2.3 Resultados

Para la primera SVM teniendo en cuenta los valores predictivos que son las medidas de precisión de las dos categorías clasificadas, medidas importantes para evaluar el rendimiento del clasificador, se puede observar que los mejores valores predictivos para las dos clases en su conjunto (valores sombreados en las tablas de ajuste de parámetros libres en *kernels*) en el *kernel* lineal son 99,9975% y 99.5215% para PPV y NPV respectivamente, en el *kernel* cuadrático son 99,9975% y 100% para PPV y NPV respectivamente, *kernel* polinomial son 99,9975% y 100% para PPV y NPV respectivamente y *kernel* base radial gaussiano son 99.5116% y 100% para PPV y NPV respectivamente. Al promediarse los valores PPV Y NPV entre sí en cada uno de los *kernels* se determina que los *kernel* con mejor rendimiento son el cuadrático con un parámetro  $C$  entre 0.4 y 1, y el polinomial con  $C$  entre 0.5 y 1 y  $d = 2$  y 3, pero se debe tener en cuenta que este último es más costoso porque consume más recursos. Las tablas con el ajuste de parámetros libres para la primera SVM se encuentran en el anexo E.

Respecto a la segunda SVM teniendo en cuenta los valores predictivos de las dos categorías, se puede observar que los mejores valores predictivos para las dos clases en su conjunto (valores sombreados en las tablas de ajuste de parámetros libres en *kernels*) en el *kernel* lineal son 63,9% y 68,5% para PPV y NPV

respectivamente, en el *kernel* cuadrático son 71,2% y 63% para PPV y NPV respectivamente, *kernel* polinomial son 69,8% y 61,2% para PPV y NPV respectivamente y *kernel* base radial gaussiano son 63% y 68,6% para PPV y NPV respectivamente. Al promediarse los valores PPV y NPV entre sí en cada uno de los *kernels* se determina que el *kernel* con mejor rendimiento es el cuadrático con un parámetro de  $C = 0.9$ . Las tablas con el ajuste de parámetros libres para la segunda SVM se encuentran en el anexo E.

Los anteriores resultados indican que la mejor función *kernel* para la implementación de las SVMs en la solución del problema planteado es la cuadrática.

Por ultimo cabe señalar que los mayores valores en cada métrica fueron resaltados en letra negra en cada una de las tablas del anexo E.

### 10.3 TIEMPO PROMEDIO DE EJECUCIÓN DE LOS ALGORITMOS

Para tener en cuenta el rendimiento de los algoritmos, se calculó el tiempo promedio para cada uno de los procesos propuestos para el procesamiento de las imágenes, como lo muestra la Tabla 18.

**Tabla 18.** Resultados tiempo promedio en segundos de los algoritmos implementados

<b>Algoritmos</b>	<b>Tiempo Promedio [S]</b>
Preprocesamiento y segmentación algoritmo Cabezas Duras	19,78
Preprocesamiento y segmentación algoritmo Potholes	132,79
Combinación Imagen	17,11
Descriptores	24,63
Clasificador1	0,78
Clasificador2	0,0095
Tiempo promedio total por imagen	195,0095

Con base en la Tabla 18, se deduce que el tiempo de ejecución del algoritmo depende en gran medida del algoritmo de preprocesamiento y de la segmentación de *potholes* o huecos. Sin embargo, el tiempo promedio por imagen es aceptable.

## 11. CONCLUSIONES

- Se implementó una herramienta *software* que permite la detección y clasificación de las fallas de tipo desprendimiento en pavimento flexible, comprendidas por cabezas duras, descascaramiento y bache.
- Se establecieron los criterios correspondientes para cada uno de los algoritmos implementados para la detección y clasificación de las fallas tipo desprendimiento en pavimento flexible.
- Mediante la utilización de la herramienta *software*, se logra la clasificación de las fallas de tipo cabezas duras, descascaramiento y bache en pavimento flexible.
- Las técnicas implementadas de procesamiento digital de imágenes, extracción de descriptores y máquinas de soporte vectorial, lograron la detección y clasificación de las fallas de tipo cabezas duras, descascaramiento y bache en pavimento flexible.
- Los resultados obtenidos en la detección y clasificación de las fallas de tipo cabezas duras, descascaramiento y bache en pavimento flexible, presentaron coherencia con los estipulados por los expertos.
- Los resultados experimentales demuestran que el método propuesto puede detectar las fallas tipo desprendimiento con las imágenes de pavimento.

## 12. RECOMENDACIONES

- A medida que se amplíe la detección y la clasificación de otros tipos de fallas, se hace necesario revisar la implementación de un nuevo clasificador.
- Utilizar arquitectura de procesamiento en paralelo, para realizar una comparación en términos de rendimiento y tiempo de cómputo.
- Continuidad en el proceso investigativo para calcular la severidad de las fallas de tipo desprendimiento en pavimento flexible.
- En futuros trabajos se recomienda incluir el cálculo de la longitud, ancho y profundidad de las fallas de tipo descascaramiento y bache, para determinar la severidad de estas fallas.

## CITAS BIBLIOGRÁFICAS

- [1] BURSANESCU, L. y Blais, F. *Automated pavement distress data collection and analysis: a 3-D approach*. in *3-D Digital Imaging and Modeling, 1997. Proceedings., International Conference on Recent Advances in*. 1997.
- [2] COMISIÓN DE INFRAESTRUCTURA. Informe. Bogotá, Octubre de 2012.
- [3] TENDENCIA ECONÓMICA No. 125. [online]. Informe Mensual de Fedesarrollo. Noviembre 2012  
<<http://idbdocs.iadb.org/wsdocs/getdocument.aspx?docnum=37933658>>
- [4] CEPAL. Cuadernos de la CEPAL N°87. Año 2003
- [5] MCGHEE, K. H., *Automated Pavement Distress Collection Techniques A Synthesis of Highway Practice*. 2004. 84p.
- [6] YU, X. *Pavement Surface Distress Detection and Evaluation Using Image Processing Technology*. 2011. Thesis.
- [7] YU, X. y SALARI, E. *Pavement pothole detection and severity measurement using laser imaging*. in *Electro/Information Technology (EIT), 2011 IEEE International Conference on*. 2011.
- [8] JIN, L. y YAYU, L. *Potholes Detection Based on SVM in the Pavement Distress Image*. in *Distributed Computing and Applications to Business Engineering and Science (DCABES), 2010 Ninth International Symposium on*. 2010.
- [9] CERVERA GONTARD, Lionel. OZKAYA, Dogan. y DUNIN-BORKOWSKI, Rafal E. *A simple algorithm for measuring particle size distributions on an uneven background from TEM images*. *En Ultramicroscopy*, Volume 111, Issue 2, January 2011, Pages 101-106, ISSN 0304-3991.
- [10] CAMACHO GRASS, Maryury Paola. *Diseño y elaboración de documentación soporte para las clases de diseño de pavimentos en el programa de Ingeniería Civil de la Universidad Industrial de Santander*. Trabajo de grado Ingeniera Civil. Bucaramanga: Universidad Industrial de Santander. Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería Civil. 2008. 339p.
- [11] MONTEJO, Alfonso. *Ingeniería de Pavimentos para Carreteras*. Segunda Edición. Ed. Universidad Católica de Colombia. Bogotá D.C. 2002. 733p. (Segunda reimpresión de la segunda edición). ISBN 958-96036-2-9.

- [12] INSTITUTO NACIONAL DE VÍAS (INVÍAS). Manual para la inspección visual de pavimentos flexibles. Estudio e investigación del estado actual de las obras de la red nacional de carreteras. Bogotá D.C.: Convenio Universidad Nacional – INVÍAS. 2006. 56p. Convenio interadministrativo 587-03.
- [13] RUSS, John C. The Image Processing Handbook, Fifth Edition, , CRC Press 2006, Pages 1–82.
- [14] GONZÁLEZ, Rafael C. Y WOODS, Richard E. Tratamiento digital de imágenes. Traducido por Fernando Davue Rodríguez, Luis Rosso y Sergio Ruiz. E.U.A.: Addison Wiley y Diaz de Santos. 1996. 800p. ISBN 0-201-62576-8.
- [15] CUEVAS, Eric., ZALDIVAR, Daniel. y PÉREZ, Marco. Procesamiento Digital de Imágenes con Matlab & Simulink. México: Alfaomega Grupo Editor, S.A. de C.V. 2010. 816p. ISBN 978-607-707-030-6.
- [16] LAORDEN FITER, Eduardo. Descripción, comparación y ejemplos de uso de las funciones de la toolbox de procesamiento digital de imágenes de Matlab. Proyecto de grado Técnico en Telecomunicaciones. Madrid: Universidad Politécnica de Madrid. Escuela Universitaria de Ingeniería. 2012. 413p.
- [17] PAJARES MARTINSANZ, Gonzalo. y DE LA CRUZ GARCÍA, Jesús M. Visión por computador. Imágenes Digitales y Aplicaciones. México: Alfaomega Grupo Editor, S.A. de C.V. 2008. 768p. ISBN 978-970-15-1356-9.
- [18] RAMÍREZ JIMÉNEZ, Sandra Magaly. Detección de grietas en la cinta asfáltica mediante análisis de imágenes. Tesis de maestría en tecnología avanzada. Santiago de Querétaro: Instituto Politécnico Nacional. Centro de Investigación en Ciencia Aplicada y Tecnología Avanzada. 2012. 79p.
- [19] SANABRIA ECHEVERRY, Duván Yahír. Algoritmo para clasificación de daños en pavimento flexible de vías urbanas. Trabajo de investigación para optar el título de Magister en Ingeniería de Sistemas e Informática. Bucaramanga: Universidad Industrial de Santander. Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería de Sistemas e Informática. 2013. 163p.
- [20] TENDENCIA ECONÓMICA No. 136. [online]. Informe Mensual de Fedesarrollo. Octubre 2013. <[http://www.fedesarrollo.org.co/wp-content/uploads/2013/12/tendencia-econ-136\\_Web.pdf](http://www.fedesarrollo.org.co/wp-content/uploads/2013/12/tendencia-econ-136_Web.pdf)>
- [21] KASS, Michael., WITKIN Andrew. y TERZOPOULOS, Demetri. Snakes: Active Contour Models. Schlumberger Palo Alto Research. International Journal of Computer Vision. 1988. 11p.

- [22] PÉREZ, M. T., VEGAS, G. y MERINO, S. Modelos variacionales para segmentación cardiaca en ultrasonidos. Universidad de Valladolid. XI Congreso de Matemática Aplicada. 2009.
- [23] AIROUCHE, M., BENTABET, L. and ZELMAT, M. Image Segmentation Using Active Contour Model and Level Set Method Applied to Detect Oil Spills. London. Proceedings of the World Congress on Engineering. Vol. I. 2009.
- [24] LANKTON, Shawn. y TANNENBAUM, Allen. Localizing Region-Based Active Contours. IEEE Transactions on Image Processing. Vol. 17 No. 11. 2008.
- [25] CHAN, Tony F. y VESE, Luminita A. Active Contours Without Edges. IEEE Transactions on Image Processing. Vol. 10 No. 02. 2001.
- [26] CHAN, Tony F., VESE, Luminita A. y SANDBERG, Yezriev. Active Contours Without Edges for Vector-Valued Images. California. Journal of Visual Communication and Image Representation 11. 2000. 12p.
- [27] MATHWORKS. [online]. Help Matlab and Simulink. <[www.mathworks.com](http://www.mathworks.com)>
- [28] GÓMEZ FLÓREZ, Luis C. Ciclos de vida de desarrollo *software* – parte II. Bucaramanga: Universidad Industrial de Santander. Grupo de Investigación en Sistemas y Tecnologías de la Información (STI). 24p.
- [29] PLATERO DUEÑAS, Carlos. Apuntes de visión artificial. Madrid: Universidad Politécnica de Madrid. Departamento de electrónica, automática e informática industrial. 2010. 22p.
- [30] PALMA MÉNDEZ, José Tomás y MARÍN MORALES, Roque. Inteligencia Artificial: Métodos, técnicas y aplicaciones. Madrid: McGraw Hill/Interamericana de España S.A.U. 2008. 1022p. ISBN 978-84-481-5618-3.
- [31] BALLAR, Dana H. y BROWN, Christopher M. Computer Vision. New Jersey: Prentice-Hall, INC. 1982. 530p. ISBN 0-13-165316-4.
- [32] CARRION, Pilar. Tecnologías avanzadas para el desarrollo de software inteligente. Vigo: Universidad de Vigo. Departamento de Informática. 2006. 43p.
- [33] MIYAMOTO, Eizan. y MERRYMAN, Thomas. Fast Calculation Of Haralick Texture Features. Pittsburgh: Carnegie Mellon University. Department of Electrical and Computer Engineering. 6p.
- [34] CASTRO CABRERA, Paola Andrea. Extracción y Selección de Características Discriminantes para la Detección de TDAH en Regiones de Potenciales Evocados Cognitivos. Manizales: Universidad Nacional de Colombia – Sede

Manizales. Facultad de Ingeniería y Arquitectura. Departamento de Ingeniería Eléctrica, Electrónica y Computación. 2011. 151p.

- [35] THEODORIDIS, Sergios. y KOUTROUMBAS, Konstantinos. An Introduction Pattern Recognition: A MATLAB Approach. Burlington U.S.A.: Elsevier Inc. 2010. 219p. ISBN 978-0-12-374486-9.
- [36] TOLEDO BAEZ, María Cristina. El resumen automático y la evaluación de traducciones en el contexto de la traducción especializada. Frankfurt: Internationaler Verlag Vorbehalten. 2010. 320p. ISBN 978-3-631-60360-4.
- [37] CAMACHO URREA, Francy Liliana. Sistema de clasificación de péptidos antibacterianos utilizando máquinas de soporte vectorial. Bucaramanga: Universidad Industrial de Santander. Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería de Sistemas e Informática. 2013. 67p.
- [38] WEIHSU, Chih., et al. A practical guide to support vector classification. Taiwan: National Taiwan University. Department of Computer Science. 2010. 16p.
- [39] GALVIS CARREÑO, Laura Viviana. Et al. Tratamiento digital de imágenes e inteligencia artificial aplicados a la perforación de pozos petroleros. Bucaramanga: Universidad Industrial de Santander. Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería de Sistemas e Informática. 2011. 31p.
- [40] SAMMUT, Claud. y WEBB, Geoffrey I. Encyclopedia of Machine Learning. New York: Springer. 2010. 1031p. ISBN 978-0-387-30164-8.
- [41] JAIN, AK. DUIN, R. P W. JIANCHANG Mao. Statistical pattern recognition: a review. Pattern Analysis and Machine Intelligence, IEEE Transactions on, Vol.22, no.1, January 2000, Pages 4-37.
- [42] CIOS, Krzysztof J. PEDRYCZ, Witold. SWINIARSKI, Roman W. KURGAN, Lukasz Andrzej. Data Mining: A Knowledge Discovery Approach. New York U.S.A: Springer Science+Business Media, LLC. 2007. 621 p. ISBN-13: 978-0-387-33333-5

## BIBLIOGRAFÍA

BALLAR, Dana H. y BROWN, Christopher M. Computer Vision. New Jersey: Prentice-Hall, INC. 1982. 530p. ISBN 0-13-165316-4.

CAMACHO GRASS, Maryury Paola. Diseño y elaboración de documentación soporte para las clases de diseño de pavimentos en el programa de Ingeniería Civil de la Universidad Industrial de Santander. Trabajo de grado Ingeniera Civil. Bucaramanga: Universidad Industrial de Santander. Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería Civil. 2008. 339p.

CAMACHO URREA, Francy Liliana. Sistema de clasificación de péptidos antibacterianos utilizando máquinas de soporte vectorial. Bucaramanga: Universidad Industrial de Santander. Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería de Sistemas e Informática. 2013. 67p.

CASTRO CABRERA, Paola Andrea. Extracción y Selección de Características Discriminantes para la Detección de TDAH en Regiones de Potenciales Evocados Cognitivos. Manizales: Universidad Nacional de Colombia – Sede Manizales. Facultad de Ingeniería y Arquitectura. Departamento de Ingeniería Eléctrica, Electrónica y Computación. 2011. 151p.

CERVERA GONTARD, Lionel. OZKAYA, Dogan. y DUNIN-BORKOWSKI, Rafal E. A simple algorithm for measuring particle size distributions on an uneven background from TEM images. En Ultramicroscopy, Volume 111, Issue 2, January 2011, Pages 101-106, ISSN 0304-3991.

CHAN, Tony F. and VESE, Luminita A. Active Contours Without Edges. IEEE Transactions on Image Processing. Vol. 10 No. 02. 2001.

CHAN, Tony F., VESE, Luminita A. and SANDBERG, Yezrielev. Active Contours Without Edges for Vector-Valued Images. California. Journal of Visual Communication and Image Representation 11. 2000. Pages 130 - 141.

CUEVAS, Eric., ZALDIVAR, Daniel. y PÉREZ, Marco. Procesamiento Digital de Imágenes con Matlab & Simulink. México: Alfaomega Grupo Editor, S.A. de C.V. 2010. 816p. ISBN 978-607-707-030-6.

GALVIS CARREÑO, Laura Viviana. Et al. Tratamiento digital de imágenes e inteligencia artificial aplicados a la perforación de pozos petroleros. Bucaramanga: Universidad Industrial de Santander. Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería de Sistemas e Informática. 2011. 31p.

GÓMEZ FLÓREZ, Luis C. Ciclos de vida de desarrollo *software* – parte II. Bucaramanga: Universidad Industrial de Santander. Grupo de Investigación en Sistemas y Tecnologías de la Información (STI). 24p.

GONZÁLEZ, Rafael C. Y WOODS, Richard E. Tratamiento digital de imágenes. Traducido por Fernando Davue Rodríguez, Luis Rosso y Sergio Ruiz. E.U.A.: Addison Wiley y Diaz de Santos. 1996. 800p. ISBN 0-201-62576-8.

INSTITUTO NACIONAL DE VÍAS (INVÍAS). Manual para la inspección visual de pavimentos flexibles. Estudio e investigación del estado actual de las obras de la red nacional de carreteras. Bogotá D.C.: Convenio Universidad Nacional – INVÍAS. 2006. 56p. Convenio interadministrativo 587-03.

JAIN, AK. DUIN, R. P W. JIANCHANG Mao. Statistical pattern recognition: a review. Pattern Analysis and Machine Intelligence, IEEE Transactions on, Vol.22, no.1, January 2000, Pages 4-37.

JIN, L. y YAYU, L. Potholes Detection Based on SVM in the Pavement Distress Image. in Distributed Computing and Applications to Business Engineering and Science (DCABES), 2010 Ninth International Symposium on. 2010.

LANKTON, Shawn. y TANNENBAUM, Allen. Localizing Region-Based Active Contours. IEEE Transactions on Image Processing. Vol. 17 No. 11. 2008.

LAORDEN FITER, Eduardo. Descripción, comparación y ejemplos de uso de las funciones de la toolbox de procesamiento digital de imágenes de Matlab. Proyecto de grado Técnico en Telecomunicaciones. Madrid: Universidad Politécnica de Madrid. Escuela Universitaria de Ingeniería. 2012. 413p.

MATHWORKS. [online]. Help Matlab and Simulink. <[www.mathworks.com](http://www.mathworks.com)>

McGHEE, K. H., Automated Pavement Distress Collection Techniques A Synthesis of Highway Practice. 2004. 84p.

MIYAMOTO, Eizan. y MERRYMAN, Thomas. Fast Calculation Of Haralick Texture Features. Pittsburgh: Carnegie Mellon University. Department of Electrical and Computer Engineering. 6p.

MONTEJO, Alfonso. Ingeniería de Pavimentos para Carreteras. Segunda Edición. Ed. Universidad Católica de Colombia. Bogotá D.C. 2002. 733p. (Segunda reimpresión de la segunda edición). ISBN 958-96036-2-9.

PAJARES MARTINSANZ, Gonzalo. y DE LA CRUZ GARCÍA, Jesús M. Visión por computador. Imágenes Digitales y Aplicaciones. México: Alfaomega Grupo Editor, S.A. de C.V. 2008. 768p. ISBN 978-970-15-1356-9.

PALMA MÉNDEZ, José Tomás y MARÍN MORALES, Roque. Inteligencia Artificial: Métodos, técnicas y aplicaciones. Madrid: McGraw Hill/Interamericana de España S.A.U. 2008. 1022p. ISBN 978-84-481-5618-3.

PLATERO DUEÑAS, Carlos. Apuntes de visión artificial. Madrid: Universidad Politécnica de Madrid. Departamento de electrónica, automática e informática industrial. 2010. 22p.

RAMÍREZ JIMÉNEZ, Sandra Magaly. Detección de grietas en la cinta asfáltica mediante análisis de imágenes. Tesis de maestría en tecnología avanzada. Santiago de Querétaro: Instituto Politécnico Nacional. Centro de Investigación en Ciencia Aplicada y Tecnología Avanzada. 2012. 79p.

SAMMUT, Claud. y WEBB, Geoffrey I. Encyclopedia of Machine Learning. New York: Springer. 2010. 1031p. ISBN 978-0-387-30164-8.

SANABRIA ECHEVERRY, Duván Yahír. Algoritmo para clasificación de daños en pavimento flexible de vías urbanas. Trabajo de investigación para optar el título de Magíster en Ingeniería de Sistemas e Informática. Bucaramanga: Universidad Industrial de Santander. Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería de Sistemas e Informática. 2013. 163p.

THEODORIDIS, Sergios. y KOUTROUMBAS, Konstantinos. An Introduction Pattern Recognition: A MATLAB Approach. Burlington U.S.A.: Elsevier Inc. 2010. 219p. ISBN 978-0-12-374486-9.

WEIHSU, Chih., et al. A practical guide to support vector classification. Taiwan: National Taiwan University. Department of Computer Science. 2010. 16p.

YU, X. Pavement Surface Distress Detection and Evaluation Using Image Processing Technology. 2011. Thesis.

## ANEXOS

### ANEXO A. REQUERIMIENTOS DEL SISTEMA

Para el correcto funcionamiento de la herramienta *software* es necesario que el equipo de cómputo cumpla las siguientes especificaciones:

- Procesador: Intel(R) Core(TM)2 Quad CPU Q8400 @ 2.66GHz.
- Memoria RAM: 8GB o superior.
- Tarjeta de video: NVIDIA Quadro FX 580 o superior.
- Resolución de monitor: 1280 x 800 píxeles.
- Sistema Operativo: Microsoft Windows 7 Professional Service Pack 1 64 bits.
- Plataforma: Matlab R2013a (8.1.0.604).
- Espacio Libre en Disco Duro: 10 GB o superior.

De no cumplirse alguno de éstos requisitos, es posible que la herramienta *software* tenga impedimentos en su correcto funcionamiento o se produzcan bloqueos en el sistema operativo.

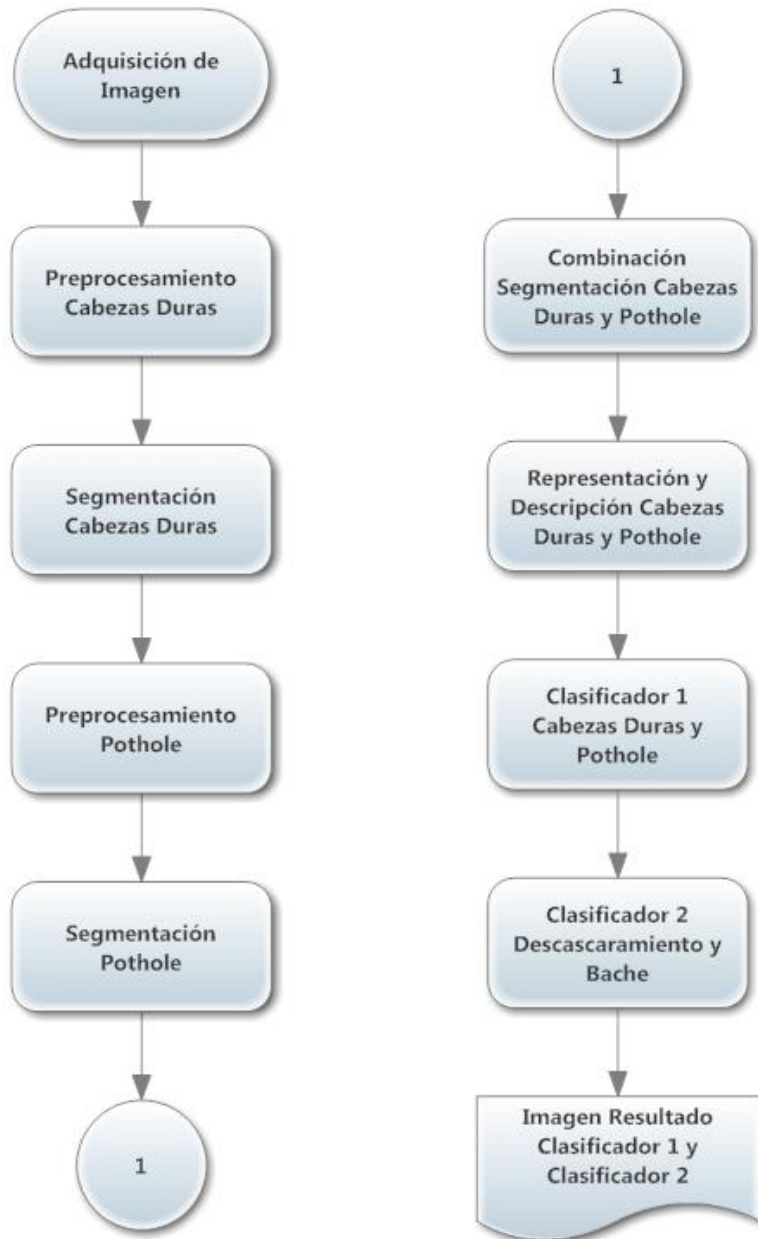
## ANEXO B. REQUISITOS FUNCIONALES Y NO FUNCIONALES

<b>REQUISITOS DESARROLLO HERRAMIENTA SOFTWARE</b>
<b>Requisitos Funcionales</b>
➤ Leer y cargar imágenes desde archivo, ya sea por única imagen o directorio de imágenes.
➤ Realizar un pre-procesado a la imagen.
➤ Segmentar la imagen.
➤ Calcular los parámetros que caracterizan los daños tipo desprendimiento.
➤ Detectar las fallas de tipo desprendimiento.
➤ Mostrar resultados obtenidos.
<b>Requisitos No Funcionales De Rendimiento</b>
➤ El sistema debe garantizar la confiabilidad, seguridad y desempeño al usuario, en cuyo caso, la información procesada y almacenada podrá ser consultada y revisada sin que se afecte el rendimiento de la herramienta.
➤ El sistema debe estar en capacidad de dar respuesta al usuario y los procesos del mismo, en tiempo de respuesta aceptable y congruente.
➤ El equipo deberá estar provisto como mínimo de un procesador Intel(R) Core(TM)2 Quad CPU Q8400 @ 2.66GHz, memoria RAM de 8GB, Windows 7 Professional SP1 64 bits y mínimo espacio libre en disco duro 10GB o superior, suficiente para almacenar las imágenes a procesar.

<b>REQUISITOS DESARROLLO HERRAMIENTA SOFTWARE</b>
<b>Requisito No Funcional De Seguridad</b>
<ul style="list-style-type: none"> <li>➤ El acceso al sistema debe estar restringido por el uso de clave a cada uno de los usuarios. Sólo podrán ingresar al sistema las personas que estén autorizadas por el grupo de investigación Geomática.</li> </ul>
<ul style="list-style-type: none"> <li>➤ El sistema debe tener confidencialidad, es decir, estar en capacidad de negar accesos o modificaciones indebidas (no autorizadas), ajenas al propietario legítimo de la herramienta.</li> </ul>
<b>Requisito No Funcional De Fiabilidad</b>
<ul style="list-style-type: none"> <li>➤ El sistema debe validar automáticamente la información asignada o contenida en los campos modificables. En el proceso de validación de la información, se debe tener en cuenta aspectos tales como obligatoriedad de campos, caracteres permitidos por campo, manejo de tipos de datos, entre otros.</li> </ul>
<b>Requisito No Funcional De Disponibilidad</b>
<ul style="list-style-type: none"> <li>➤ El sistema debe estar disponible en el horario hábil laboral del usuario.</li> </ul>
<b>Requisito No Funcional De Mantenimiento</b>
<ul style="list-style-type: none"> <li>➤ Los algoritmos de los componentes que forman parte de la solución propuesta, deberán estar debidamente comentados, para futuros desarrollos complementarios o cambios necesarios en la herramienta.</li> </ul>
<b>Otros Requisitos</b>
<ul style="list-style-type: none"> <li>➤ La herramienta debe estar en capacidad de integrar los diferentes algoritmos implementados para la detección de fallas en pavimento flexible.</li> </ul>
<ul style="list-style-type: none"> <li>➤ La herramienta debe presentar mensajes de error o advertencia que le permitan al usuario identificarlos.</li> </ul>

## ANEXO C. DIAGRAMA DE FLUJO DE LA HERRAMIENTA SOFTWARE

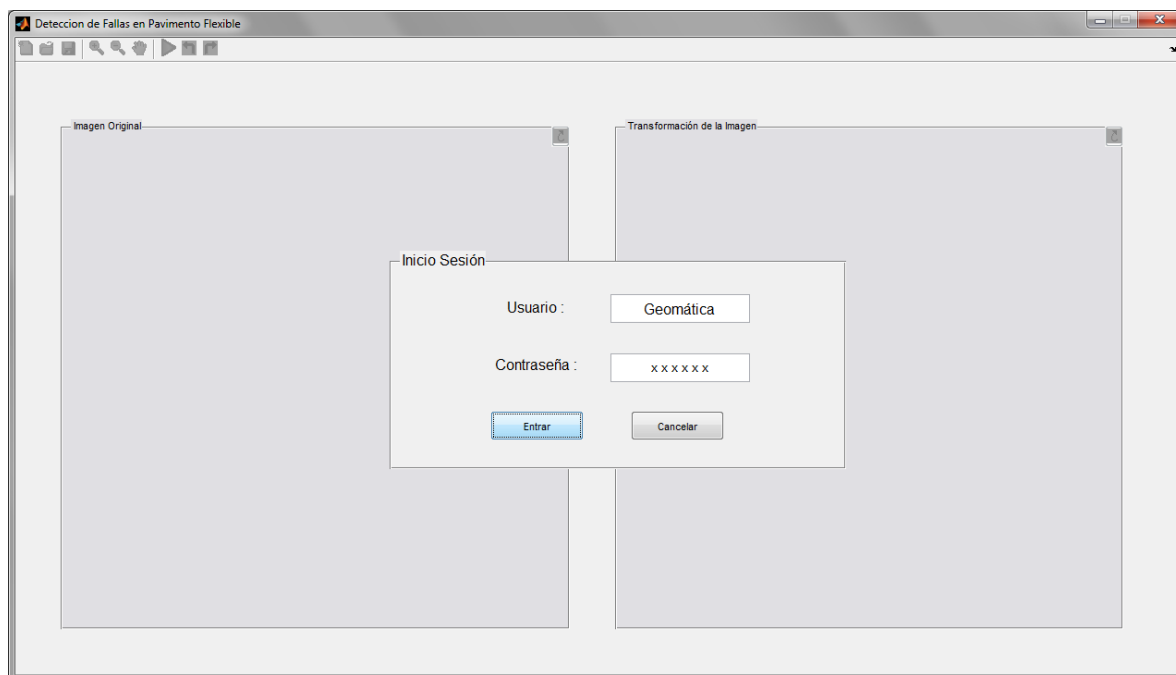
Figura 50. Diagrama de flujo de la herramienta software



## ANEXO D. FUNCIONAMIENTO DE LA HERRAMIENTA *SOFTWARE*

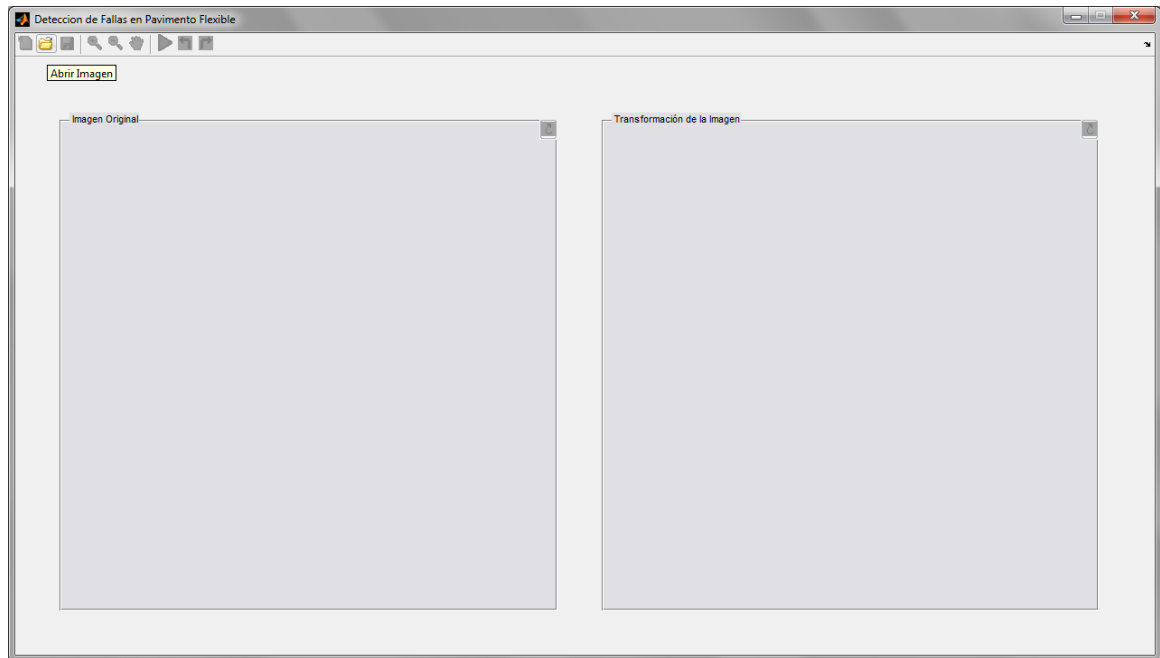
A continuación se presenta una guía básica del funcionamiento de la herramienta *software* desarrollada en éste proyecto. La primera pantalla que se observa es el inicio de sesión de usuario (Figura 51).

**Figura 51.** Inicio de sesión de la herramienta *software*




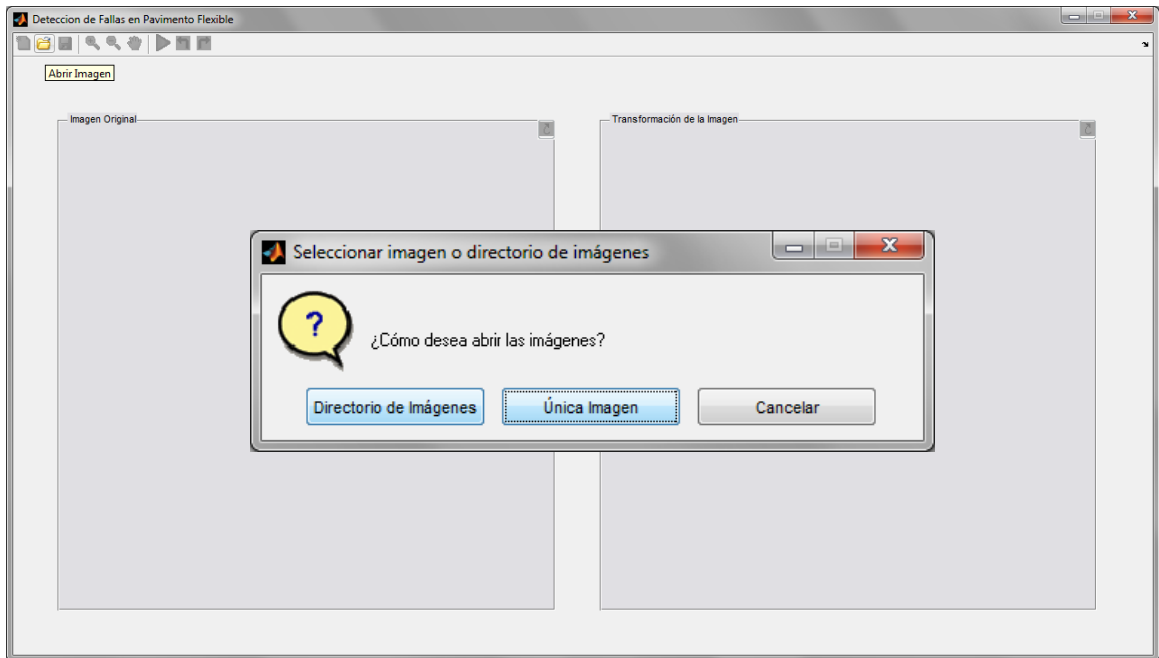
Una vez iniciada sesión en la herramienta *software*, se activa el panel de herramientas ubicado en la parte superior de la ventana emergente (Figura 52).

**Figura 52.** Primera interfaz de usuario iniciada la herramienta software



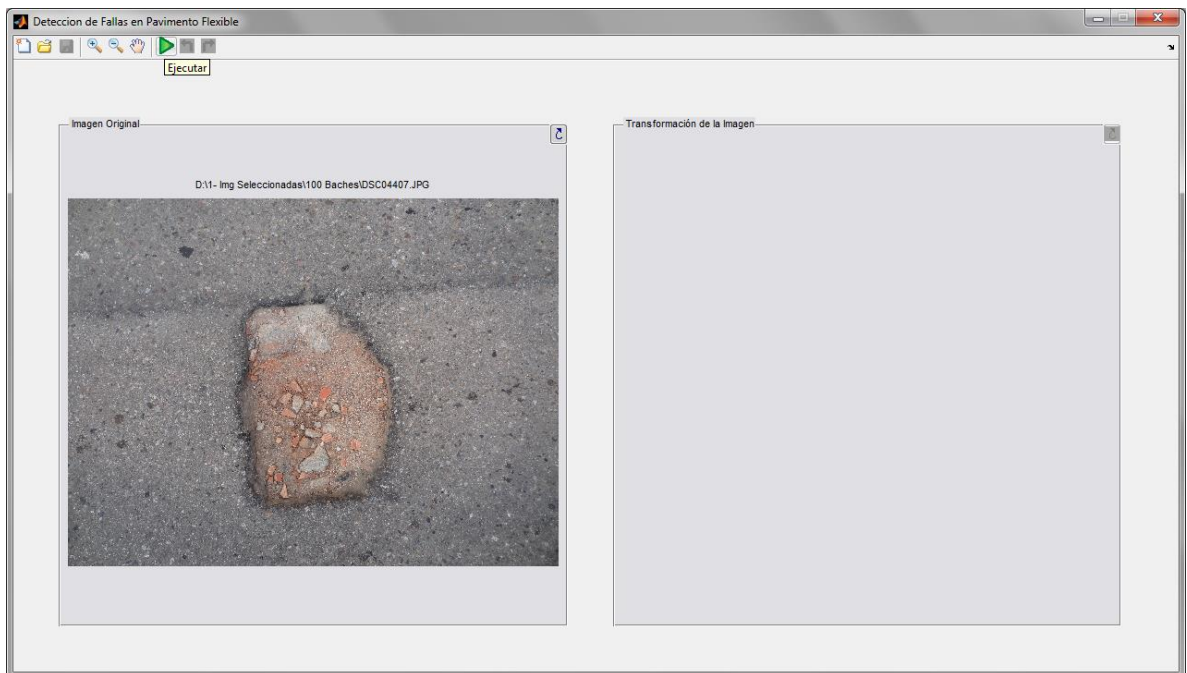
Para iniciar a utilizar la herramienta, se debe dar *click* en el ícono de abrir imagen ubicado a la izquierda del panel de herramientas; para abrir las imágenes a procesar, la herramienta presenta dos opciones, la primera abrir directorio de imágenes y la segunda, abrir única imagen, tal como se muestra en la Figura 53.

Figura 53. Abrir directorio de imágenes o única imagen




Al seleccionar la opción de abrir directorio de imágenes, la herramienta automáticamente inicia el procesamiento de las imágenes en el directorio seleccionado. Para el caso de seleccionar única imagen, la herramienta muestra en pantalla la imagen seleccionada y espera a que el usuario de *click* en el ícono de ejecutar del panel de herramientas, permitiendo así cambiar de imagen en caso de ser deseado, previo al inicio del procesamiento de la imagen (Figura 54).

**Figura 54.** Ejecución única imagen



La Figura 55 muestra el resultado del procesamiento de una imagen seleccionada.

**Figura 55.** Resultado procesamiento única imagen seleccionada.



## ANEXO E. TABLAS DE AJUSTE DE PARÁMETROS LIBRES EN KERNELS

### Tablas Cabezas Duras-Pothole

**Tabla 19.** Tabla función *kernel* lineal clasificador 1

<b>C</b>	<b>0,1</b>	<b>0,2</b>	<b>0,3</b>	<b>0,4</b>	<b>0,5</b>	<b>0,6</b>	<b>0,7</b>	<b>0,8</b>	<b>0,9</b>	<b>1</b>
Sensibilidad	1,000	1,000	1,000	1,000	1,000	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
Especificidad	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>
PPV	1,000	1,000	1,000	1,000	1,000	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
NPV	0,963	0,986	0,990	0,990	0,990	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>
CCM	0,047	0,049	0,049	0,049	0,049	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>

**Tabla 20.** Tabla función *kernel* cuadrático clasificador 1

<b>C</b>	<b>0,1</b>	<b>0,2</b>	<b>0,3</b>	<b>0,4</b>	<b>0,5</b>	<b>0,6</b>	<b>0,7</b>	<b>0,8</b>	<b>0,9</b>	<b>1</b>
Sensibilidad	1,000	1,000	1,000	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
Especificidad	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>
PPV	1,000	1,000	1,000	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
NPV	0,995	0,995	0,995	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
CCM	0,050	0,050	0,050	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>

## Kernel Polinomial

**Tabla 21.** Tabla sensibilidad para función *kernel* polinomial clasificador 1

<b>C d</b>	<b>0,1</b>	<b>0,2</b>	<b>0,3</b>	<b>0,4</b>	<b>0,5</b>	<b>0,6</b>	<b>0,7</b>	<b>0,8</b>	<b>0,9</b>	<b>1</b>
1	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
2	1,000	1,000	1,000	1,000	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
3	<b>1,000</b>	<b>1,000</b>	1,000	1,000	1,000	<b>1,000</b>	<b>1,000</b>	1,000	1,000	1,000
4	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
5	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000

**Tabla 22.** Tabla especificidad para función *kernel* polinomial clasificador 1

<b>C d</b>	<b>0,1</b>	<b>0,2</b>	<b>0,3</b>	<b>0,4</b>	<b>0,5</b>	<b>0,6</b>	<b>0,7</b>	<b>0,8</b>	<b>0,9</b>	<b>1</b>
1	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>
2	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>
3	0,990	0,990	<b>0,995</b>	0,990	<b>0,995</b>	<b>0,995</b>	<b>0,995</b>	0,990	0,990	0,990
4	0,990	0,986	0,990	0,981	0,990	0,990	0,990	0,990	0,986	0,986
5	0,990	0,990	0,990	0,990	<b>0,995</b>	0,990	0,986	0,986	0,990	0,990

**Tabla 23.** Tabla PPV para función *kernel* polinomial clasificador 1

<b>C d</b>	<b>0,1</b>	<b>0,2</b>	<b>0,3</b>	<b>0,4</b>	<b>0,5</b>	<b>0,6</b>	<b>0,7</b>	<b>0,8</b>	<b>0,9</b>	<b>1</b>
1	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
2	1,000	1,000	1,000	1,000	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
3	1,000	1,000	1,000	1,000	1,000	<b>1,000</b>	<b>1,000</b>	1,000	1,000	1,000
4	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
5	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000

**Tabla 24.** Tabla NPV para función *kernel* polinomial clasificador 1

C d	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
1	0,959	0,990	0,986	0,986	0,995	0,995	0,995	0,995	0,995	0,995
2	0,995	0,995	0,995	0,995	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
3	<b>1,000</b>	<b>1,000</b>	0,995	0,995	0,995	<b>1,000</b>	<b>1,000</b>	0,995	0,995	0,995
4	0,995	0,995	0,995	0,995	0,995	0,995	0,990	0,995	0,990	0,995
5	0,990	0,981	0,995	0,995	0,981	0,995	0,990	0,990	0,986	0,990

**Tabla 25.** Tabla CCM para función *kernel* polinomial clasificador 1

C d	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
1	0,047	0,049	0,049	0,049	0,050	0,050	0,050	0,050	0,050	0,050
2	0,050	0,050	0,050	0,050	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>
3	0,050	0,050	0,050	0,050	0,050	<b>0,050</b>	<b>0,050</b>	0,050	0,050	0,050
4	0,050	0,050	0,050	0,049	0,050	0,050	0,049	0,050	0,049	0,050
5	0,049	0,049	0,050	0,050	0,049	0,050	0,049	0,049	0,049	0,049

### Kernel Base Radial Gaussiano

**Tabla 26.** Tabla sensibilidad para función *kernel* base radial gaussiano clasificador 1

C Gamma	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
0,05	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
0,1	0,996	0,997	0,998	0,999	0,999	0,999	1,000	1,000	1,000	1,000
0,15	0,996	0,998	0,998	0,999	0,999	0,999	0,999	1,000	1,000	1,000
0,2	0,997	0,998	0,999	0,999	1,000	1,000	1,000	1,000	1,000	1,000
0,25	0,997	0,999	0,999	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,3	0,998	0,999	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,35	0,998	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,4	0,998	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,45	0,999	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,5	0,999	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000

**Tabla 27.** Tabla de especificidad para función *kernel* base radial gaussiano clasificador 1

C Gamma	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
0,05	0,033	0,024	0,024	0,019	0,019	0,010	0,019	0,010	0,019	0,019
0,1	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
0,15	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
0,2	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
0,25	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
0,3	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	0,995	0,995	0,995	0,995
0,35	<b>1,000</b>	1,000	0,995	0,995	0,995	0,995	0,995	0,995	0,995	0,995
0,4	<b>1,000</b>	0,995	0,995	0,995	0,995	0,995	0,995	0,995	0,995	0,995
0,45	0,995	0,995	0,995	0,995	0,995	0,995	0,995	0,995	0,995	0,995
0,5	0,995	0,995	0,995	0,995	0,995	0,995	0,995	0,995	0,995	0,995

**Tabla 28.** Tabla PPV para función *kernel* base radial gaussiano clasificador 1

C Gamma	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
0,05	0,995	0,995	0,995	0,995	0,995	0,995	0,995	0,995	0,995	0,995
0,1	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
0,15	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
0,2	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
0,25	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
0,3	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	1,000	1,000	1,000	1,000
0,35	<b>1,000</b>	<b>1,000</b>	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,4	<b>1,000</b>	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,45	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000
0,5	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000

**Tabla 29.** Tabla NPV para función *kernel* base radial gaussiano clasificador 1

C Gamma	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
0,05	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>	<b>1,000</b>
0,1	0,546	0,663	0,760	0,826	0,867	0,897	0,921	0,921	0,941	0,950
0,15	0,589	0,672	0,763	0,810	0,857	0,897	0,897	0,917	0,941	0,954
0,2	0,628	0,716	0,833	0,878	0,925	0,937	0,946	0,963	0,959	0,977
0,25	0,661	0,795	0,882	0,929	0,954	0,963	0,977	0,977	0,986	0,986
0,3	0,690	0,860	0,937	0,954	0,972	0,981	0,990	0,990	0,990	0,990
0,35	0,728	0,921	0,950	0,963	0,990	0,990	0,990	0,990	0,990	0,990
0,4	0,744	0,937	0,972	0,981	0,981	0,990	0,995	0,995	0,995	0,995
0,45	0,776	0,950	0,972	0,986	0,990	0,995	0,995	0,995	0,995	0,995
0,5	0,829	0,959	0,986	0,990	0,990	0,995	0,995	0,995	0,995	0,995

**Tabla 30.** Tabla CCM para función *kernel* base radial gaussiano clasificador 1

C Gamma	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
0,05	0,009	0,008	0,008	0,007	0,007	0,005	0,007	0,005	0,007	0,007
0,1	0,006	0,020	0,030	0,036	0,040	0,042	0,044	0,044	0,046	0,046
0,15	0,012	0,021	0,030	0,035	0,039	0,042	0,042	0,044	0,046	0,047
0,2	0,016	0,026	0,037	0,041	0,044	0,045	0,046	0,047	0,047	0,048
0,25	0,020	0,033	0,041	0,045	0,047	0,047	0,048	0,048	0,049	0,049
0,3	0,023	0,039	0,045	0,047	0,048	0,049	0,049	0,049	0,049	0,049
0,35	0,027	0,044	0,046	0,047	0,049	0,049	0,049	0,049	0,049	0,049
0,4	0,028	0,045	0,048	0,049	0,049	0,049	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>
0,45	0,031	0,046	0,048	0,049	0,049	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>
0,5	0,036	0,047	0,049	0,049	0,049	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>	<b>0,050</b>

## Tablas Descascaramiento-Bache

**Tabla 31.** Tabla función *kernel* lineal clasificador 2

C	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
Sensibilidad	0,594	0,594	<b>0,646</b>	0,635	0,635	0,604	0,615	0,635	0,625	0,635
Especificidad	0,651	0,633	<b>0,679</b>	0,651	0,642	0,661	0,606	0,651	0,633	0,661
PPV	0,600	0,588	<b>0,639</b>	0,616	0,610	0,611	0,578	0,616	0,600	0,622
NPV	0,645	0,639	<b>0,685</b>	0,670	0,667	0,655	0,641	0,670	0,657	0,673
CCM	0,147	0,140	<b>0,188</b>	0,172	0,168	0,156	0,142	0,172	0,159	0,175

**Tabla 32.** Tabla función *kernel* cuadrático clasificador 2

C	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
Sensibilidad	0,344	0,417	0,385	0,417	0,427	0,417	<b>0,438</b>	0,417	<b>0,438</b>	0,417
Especificidad	0,826	0,817	0,826	0,807	0,780	0,798	0,807	0,807	<b>0,844</b>	0,826
PPV	0,635	0,667	0,661	0,656	0,631	0,645	0,667	0,656	<b>0,712</b>	0,678
NPV	0,588	0,614	0,604	0,611	0,607	0,608	0,620	0,611	<b>0,630</b>	0,616
CCM	0,082	0,110	0,099	0,108	0,104	0,105	0,117	0,108	<b>0,127</b>	0,113

### Kernel Polinomial

**Tabla 33.** Tabla Sensibilidad para función *kernel* polinomial clasificador 2

<b>C d</b>	<b>0,1</b>	<b>0,2</b>	<b>0,3</b>	<b>0,4</b>	<b>0,5</b>	<b>0,6</b>	<b>0,7</b>	<b>0,8</b>	<b>0,9</b>	<b>1</b>
1	<b>0,625</b>	0,615	<b>0,625</b>	<b>0,625</b>	0,615	0,615	0,615	0,604	<b>0,625</b>	0,594
2	0,385	0,427	0,375	0,406	0,385	0,406	0,396	0,438	0,406	0,438
3	0,479	0,427	0,552	0,583	0,552	0,552	0,583	0,573	0,542	0,563
4	0,469	0,438	0,469	0,542	0,521	0,552	0,552	0,531	0,531	0,521
5	0,521	0,500	0,510	0,469	0,469	0,510	0,438	0,510	0,500	0,521

**Tabla 34.** Tabla especificidad para función *kernel* polinomial clasificador 2

<b>C d</b>	<b>0,1</b>	<b>0,2</b>	<b>0,3</b>	<b>0,4</b>	<b>0,5</b>	<b>0,6</b>	<b>0,7</b>	<b>0,8</b>	<b>0,9</b>	<b>1</b>
1	0,661	0,651	0,651	0,624	0,661	0,615	0,642	0,670	0,642	0,606
2	<b>0,853</b>	0,826	0,835	0,798	0,798	0,807	0,835	0,817	0,807	0,798
3	0,752	0,725	0,734	0,725	0,725	0,725	0,716	0,706	0,734	0,697
4	0,771	0,734	0,734	0,734	0,679	0,697	0,716	0,688	0,661	0,679
5	0,725	0,725	0,697	0,633	0,606	0,679	0,633	0,633	0,651	0,642

**Tabla 35.** Tabla PPV para función *kernel* polinomial clasificador 2

<b>C d</b>	<b>0,1</b>	<b>0,2</b>	<b>0,3</b>	<b>0,4</b>	<b>0,5</b>	<b>0,6</b>	<b>0,7</b>	<b>0,8</b>	<b>0,9</b>	<b>1</b>
1	0,619	0,608	0,612	0,594	0,615	0,584	0,602	0,617	0,606	0,570
2	<b>0,698</b>	0,683	0,667	0,639	0,627	0,650	0,679	0,677	0,650	0,656
3	0,630	0,577	0,646	0,651	0,639	0,639	0,644	0,632	0,642	0,621
4	0,643	0,592	0,608	0,642	0,588	0,616	0,631	0,600	0,580	0,588
5	0,625	0,615	0,598	0,529	0,511	0,583	0,512	0,551	0,558	0,562

**Tabla 36.** Tabla NPV para función *kernel* polinomial clasificador 2

C d	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
1	<b>0,667</b>	0,657	0,664	0,654	0,661	0,644	0,654	0,658	0,660	0,629
2	<b>0,612</b>	0,621	0,603	0,604	0,596	0,607	0,611	0,622	0,607	0,617
3	0,621	0,590	0,650	0,664	0,648	0,648	0,661	0,653	0,645	0,644
4	0,622	0,597	0,611	0,645	0,617	0,639	0,645	0,625	0,615	0,617
5	0,632	0,622	0,618	0,575	0,564	0,612	0,561	0,595	0,597	0,603

**Tabla 37.** Tabla CCM para función *kernel* polinomial clasificador 2

C d	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
1	<b>0,169</b>	0,159	0,165	0,155	0,162	0,145	0,156	0,160	0,162	0,129
2	0,106	0,117	0,097	0,100	0,091	0,103	0,106	0,120	0,103	0,114
3	0,120	0,087	0,152	0,166	0,149	0,149	0,163	0,154	0,146	0,146
4	0,121	0,095	0,110	0,146	0,117	0,140	0,146	0,126	0,116	0,117
5	0,133	0,122	0,118	0,075	0,064	0,112	0,060	0,095	0,097	0,104

### Kernel Base Radial Gaussiano

**Tabla 38.** Tabla sensibilidad para función *kernel* base radial gaussiano clasificador 2

C Gamma	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
0,05	<b>0,865</b>	0,750	0,781	0,792	0,781	0,781	<b>0,865</b>	0,771	0,750	0,021
0,1	0,156	0,167	0,188	0,229	0,125	0,250	0,083	0,073	0,115	0,094
0,15	0,396	0,292	0,313	0,260	0,365	0,229	0,313	0,448	0,542	0,229
0,2	0,510	0,635	0,583	0,635	0,563	0,573	0,552	0,531	0,531	0,490
0,25	0,677	0,677	0,740	0,688	0,583	0,583	0,583	0,573	0,594	0,542
0,3	0,719	0,698	0,698	0,635	0,615	0,604	0,594	0,594	0,583	0,615
0,35	0,760	0,729	0,708	0,625	0,635	0,646	0,635	0,604	0,615	0,604
0,4	0,719	0,667	0,688	0,667	0,667	0,646	0,615	0,625	0,563	0,531
0,45	0,667	0,698	0,688	0,667	0,646	0,646	0,625	0,656	0,635	0,604
0,5	0,625	0,667	0,677	0,625	0,646	0,656	0,625	0,646	0,594	0,646

**Tabla 39.** Tabla de especificidad para función *kernel* base radial gaussiano clasificador 2

C Gamma	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
0,05	0,119	0,202	0,193	0,211	0,193	0,220	0,073	0,211	0,211	<b>0,963</b>
0,1	0,743	0,761	0,743	0,807	0,853	0,734	0,862	0,908	0,798	0,853
0,15	0,615	0,688	0,642	0,679	0,679	0,688	0,642	0,532	0,541	0,661
0,2	0,459	0,450	0,459	0,404	0,505	0,514	0,532	0,486	0,523	0,587
0,25	0,431	0,431	0,376	0,450	0,606	0,615	0,560	0,541	0,596	0,560
0,3	0,440	0,468	0,450	0,495	0,514	0,550	0,550	0,587	0,578	0,606
0,35	0,523	0,486	0,523	0,523	0,624	0,587	0,560	0,578	0,541	0,606
0,4	0,514	0,532	0,560	0,587	0,615	0,569	0,615	0,578	0,587	0,596
0,45	0,624	0,587	0,624	0,606	0,642	0,624	0,615	0,661	0,615	0,596
0,5	0,615	0,651	0,642	0,587	0,633	0,633	0,633	0,642	0,606	0,651

**Tabla 40.** Tabla PPV para función *kernel* base radial gaussiano clasificador 2

C Gamma	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
0,05	0,464	0,453	0,460	0,469	0,460	0,469	0,451	0,463	0,456	0,333
0,1	0,349	0,381	0,391	0,512	0,429	0,453	0,348	0,412	0,333	0,360
0,15	0,475	0,452	0,435	0,417	0,500	0,393	0,435	0,457	0,510	0,373
0,2	0,454	0,504	0,487	0,484	0,500	0,509	0,510	0,477	0,495	0,511
0,25	0,512	0,512	0,511	0,524	0,566	0,571	0,538	0,524	0,564	0,520
0,3	0,531	0,536	0,528	0,526	0,527	0,542	0,538	0,559	0,549	0,578
0,35	0,584	0,556	0,567	0,536	0,598	0,579	0,560	0,558	0,541	0,574
0,4	0,566	0,557	0,579	0,587	0,604	0,569	0,584	0,566	0,545	0,537
0,45	0,610	0,598	0,617	0,598	0,614	0,602	0,588	<b>0,630</b>	0,592	0,569
0,5	0,588	0,627	0,625	0,571	0,608	0,612	0,600	0,614	0,570	0,620

**Tabla 41.** Tabla NPV para función *kernel* base radial gaussiano clasificador 2

C Gamma	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
0,05	0,500	0,478	0,500	0,535	0,500	0,533	0,381	0,511	0,489	0,528
0,1	0,500	0,509	0,509	0,543	0,525	0,526	0,516	0,527	0,506	0,517
0,15	0,536	0,524	0,515	0,510	0,548	0,503	0,515	0,523	0,573	0,493
0,2	0,515	0,583	0,556	0,557	0,567	0,577	0,574	0,541	0,559	0,566
0,25	0,603	0,603	0,621	0,620	0,623	0,626	0,604	0,590	0,625	0,581
0,3	0,640	0,638	0,628	0,607	0,602	0,612	0,606	0,621	0,612	0,641
0,35	<b>0,713</b>	0,671	0,671	0,613	0,660	0,653	0,635	0,624	0,615	0,635
0,4	0,675	0,644	0,670	0,667	0,677	0,646	0,644	0,636	0,604	0,591
0,45	0,680	0,688	0,694	0,673	0,673	0,667	0,650	0,686	0,657	0,631
0,5	0,650	0,689	0,693	0,640	0,670	0,676	0,657	0,673	0,629	0,676

**Tabla 42.** Tabla CCM para función *kernel* base radial gaussiano clasificador 2

C Gamma	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
0,05	0,000	-0,019	0,000	0,029	0,000	0,028	-0,075	0,009	-0,009	0,008
0,1	0,000	0,007	0,007	0,036	0,017	0,022	0,009	0,014	0,004	0,010
0,15	0,035	0,022	0,014	0,009	0,046	0,003	0,014	0,022	0,073	-0,006
0,2	0,015	0,082	0,055	0,056	0,067	0,077	0,074	0,041	0,059	0,066
0,25	0,100	0,100	0,113	0,117	0,123	0,127	0,104	0,090	0,126	0,081
0,3	0,134	0,134	0,124	0,106	0,102	0,112	0,106	0,122	0,112	0,142
0,35	<b>0,206</b>	0,165	0,167	0,113	0,161	0,153	0,135	0,124	0,115	0,136
0,4	0,171	0,143	0,169	0,167	0,177	0,146	0,145	0,137	0,104	0,091
0,45	0,181	0,187	0,194	0,174	0,175	0,168	0,152	0,188	0,158	0,132
0,5	0,152	0,191	0,194	0,141	0,171	0,178	0,159	0,175	0,129	0,178