

**DETECCIÓN DE MINAS ANTIPERSONAL TIPO QUIEBRAPATAS MEDIANTE
EL ANÁLISIS DE IMÁGENES TERMOGRÁFICAS AÉREAS DEL SUELO**

ING. JUAN CAMILO FORERO RAMÍREZ



**UNIVERSIDAD DEL VALLE
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA
PROGRAMA DE POSGRADOS EN INGENIERÍA ELÉCTRICA Y ELECTRÓNICA
SANTIAGO DE CALI
2022**

**DETECCIÓN DE MINAS ANTIPERSONAL TIPO QUIEBRAPATAS MEDIANTE
EL ANÁLISIS DE IMÁGENES TERMOGRÁFICAS AÉREAS DEL SUELO**

ING. JUAN CAMILO FORERO RAMÍREZ

Trabajo de investigación para optar por el título de Magister en Ingeniería

Directores:

**Profesor, Andrés David Restrepo Girón, Ph.D.
Profesora, Sandra Esperanza Nope Rodríguez, Ph.D.**



**UNIVERSIDAD DEL VALLE
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA
PROGRAMA DE POSGRADOS EN INGENIERÍA ELÉCTRICA Y ELECTRÓNICA
SANTIAGO DE CALI
2022**

AGRADECIMIENTOS

Quiero agradecer a mis directores Andrés David Restrepo Girón y Sandra Esperanza Nope Rodríguez por el apoyo, asesoría y confianza a lo largo del desarrollo de este trabajo.

A mi esposa y padres por bríndame el cariño y motivación necesaria para culminar mis estudios de maestría.

A la Universidad del Valle y al Minciencias por financiar mis estudios y otorgar los recursos para el desarrollo de esta investigación.

TABLA DE CONTENIDO

1	INTRODUCCIÓN	12
2	MARCO REFERENCIAL	15
2.1	ANTECEDENTES	15
2.2	MARCO TEORICO.....	22
2.2.1	Minas Antipersonal (MAPs)	22
2.2.2	Métodos de detección de Minas Antipersonal (MAPs)	24
2.2.3	Medición Termográfica	26
2.2.4	Compensación Térmica de Fondo mediante Filtrado (CTFF).....	29
2.2.5	Máquinas de Vectores de Soporte (SVM)	33
2.2.6	Redes Neuronales Artificiales (RNA).....	36
2.2.7	Redes Bayesianas.....	38
2.2.8	K-Vecinos más cercanos (KNN)	38
3	DISEÑO METODOLÓGICO	40
3.1	DISEÑO DEL EXPERIMENTO	40
3.2	METODOLOGÍA PARA LA DETECCIÓN DE MAP A PARTIR DE IMÁGENES IR.....	42
3.2.1	Etapa de Sensado	42
3.2.2	Etapa de Preprocesamiento	45
3.2.3	Etapa de Extracción y Selección de Características.....	49
3.2.4	Etapa de Entrenamiento	54
3.2.5	Etapa de Clasificación	56
3.2.6	Etapa de Posprocesamiento.....	57
4	RESULTADOS	60
4.1	RESULTADOS DE CLASIFICACIÓN CON LOS DATOS DE ENTRENAMIENTO Y PRUEBA.....	60

4.1.1	Resultados de entrenamiento y prueba para el clasificador Perceptrón Multicapa (MLP)	62
4.1.2	Resultados de entrenamiento y prueba para el clasificador Máquinas de Vectores de Soporte (SVM)	63
4.1.3	Resultados de entrenamiento y prueba para el clasificador Naive Bayes4.....	64
4.1.4	Resultados de entrenamiento y prueba para el clasificador Red de Base Radial (RBF)	65
4.1.5	Resultados de entrenamiento y prueba para el clasificador K-Vecinos más cercanos (KNN).....	66
4.2	RESULTADOS DE CLASIFICACIÓN USANDO LA TÉCNICA DE VENTANA DESLIZANTE SOBRE EL TOTAL DE IMÁGENES TERMOGRÁFICAS AÉREAS DEL SUELO SIN CONTRASTAR CAPTURADAS A 1 M DE ALTURA	67
4.2.1	Resultados de detección de MAP en imágenes termográficas adquiridas en Febrero 13, 2020	71
4.2.2	Resultados de detección de MAP en imágenes termográficas adquiridas en Febrero 24, 2020	72
4.2.3	Resultados de detección de MAP en imágenes termográficas adquiridas en Marzo 3, 2020.....	74
4.3	RESULTADOS EXPLORATORIOS DE CLASIFICACIÓN USANDO LA TÉCNICA DE VENTANA DESLIZANTE SOBRE EL TOTAL DE IMÁGENES TERMOGRÁFICAS AÉREAS DEL SUELO SIN CONTRASTAR CAPTURADAS A ALTURAS ENTRE 2 Y 5 M	75
5	CONCLUSIONES	78
5.1	PRODUCTOS DEL TRABAJO DE INVESTIGACIÓN	80
5.2	TRABAJOS FUTUROS	80

LISTA DE TABLAS

Tabla 2. 1. Trabajos de investigación precisando técnicas, metodología y resultados en el detección de MAPs.....	20
Tabla 2. 2. Trabajos de investigación en detección de MAPs usando VANT.....	21
Tabla 3. 1. Propiedades térmicas del TNT y del carbón de antracita usado en remplazo del primero.....	41
Tabla 3. 2. Especificaciones de la cámara termográfica.	43
Tabla 3. 3. Especificaciones del UAV.	43
Tabla 3. 4. Condiciones ambientales para cada experimento de inspección.....	43
Tabla 3. 5. Banco de imágenes IR adquiridas según fecha de adquisición, altura de adquisición y zona.....	45
Tabla 3. 6. Relaciones entre dimensiones espaciales y su correspondencia en píxeles para las diferentes alturas de adquisición de las imágenes térmicas.	51
Tabla 3. 7. Tamaño de ROI para alturas superiores a 1 metro.	52
Tabla 3. 8. Características extraídas por ROI.	53
Tabla 3. 9. Definición de parámetros utilizados para las ventanas deslizantes cuando la captura de las imágenes se realiza a 1 m de altura.....	56
Tabla 4. 1. Resultados para los datos de entrenamiento de los cinco clasificadores...	61
Tabla 4. 2. Resultados para los datos de prueba de los cinco clasificadores.	61
Tabla 4. 3. Matrices de confusión de entrenamiento del clasificador MLP. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.....	62
Tabla 4. 4. Matrices de confusión de prueba del clasificador MLP. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.....	62
Tabla 4. 5. Matrices de confusión de entrenamiento del clasificador SVM. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.....	63
Tabla 4. 6. Matrices de confusión de prueba del clasificador SVM. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.....	63
Tabla 4. 7. Matrices de confusión de entrenamiento del clasificador Naive Bayes. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.....	64

Tabla 4. 8. Matrices de confusión de prueba del clasificador Naive Bayes. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.....	64
Tabla 4. 9. Matrices de confusión de entrenamiento del clasificador RBF. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.....	65
Tabla 4. 10. Matrices de confusión de prueba del clasificador RBF. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.....	65
Tabla 4. 11. Matrices de confusión de entrenamiento del clasificador KNN. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.....	66
Tabla 4. 12. Matrices de confusión de prueba del clasificador KNN. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.....	66
Tabla 4. 13. Resultados de clasificación en la detección de MAP por diferentes criterios de agrupamiento para imágenes sin contrastar.	69
Tabla 4. 14. Resultados de segmentación de la MAP por zona de inspección y clasificador para la fecha Febrero 13, 2020.	71
Tabla 4. 15. Resultados de segmentación de la MAP por zona de inspección y clasificador para la fecha Febrero 24, 2020.	73
Tabla 4. 16. Resultados de segmentación de la MAP por zona de inspección y clasificador para la fecha Febrero 24, 2020.	74
Tabla 4. 17. Definición de parámetros utilizados para cada conjunto de imágenes según la altura de adquisición para la etapa de clasificación con ventana	75
Tabla 4. 18. Resultados para los datos de prueba del clasificador MLP por conjunto de imágenes según altura.	76
Tabla 4. 19. Resultados de clasificación en la detección de MAP para imágenes sin contrastar para el clasificador MLP por altura.	77

LISTA DE FIGURAS

Figura 2. 1. Tendencia de la investigación sobre detección de Minas Antipersonal [4].	15
Figura 2. 2. Países líderes en publicaciones de investigación sobre detección de Minas Antipersonal [4].	16
Figura 2. 3. Experimento de termografía activa para la detección de MAP propuesta por [31].	17
Figura 2. 4. Sistema de Inspección termográfico mediante un dron propuesto por [40].	18
Figura 2. 5. Diferentes Minas Antipersonal Artesanales usadas en Colombia: a) Mina Quiebrapatas, b) Mina Abanico, c) Mina Cumbo pequeño, d) Mina Sombrero pequeño, e) Mina Quiebrapatas química, f) Mina Cilindro, g) Mina Cumbo, h) Mina sombrero Chino [72].	22
Figura 2. 6. Detector de Metales para la detección de MAPs [74].	24
Figura 2. 7. Radar de Penetración Terrestre para la detección de MAPs [75].	25
Figura 2. 8. Cámaras IR para la detección de MAPs [72].	25
Figura 2. 9. Los actores del acto termográfico y los fenómenos físicos que intervienen en la medición [76].	26
Figura 2. 10. Los dos tipos de detectores infrarrojos [76].	27
Figura 2. 11. Indicatrices de emisión del cuerpo negro, del cuerpo gris y de los dos tipos de materiales (dieléctricos y metálicos) [76].	28
Figura 2. 12. Ejemplo de máscara modificada para el filtro mediana diezmo [78].	31
Figura 2. 13. a) Comparación entre un perfil original, y el perfil de calentamiento de fondo estimado; b) Resultado de la resta entre los dos perfiles anteriores [78]. ...	32
Figura 2. 14. Comparación entre un termograma original, su perfil de calentamiento de fondo estimado y su versión contrastada [78].	33
Figura 2. 15. Hiperplano de separación lineal considerando el máximo margen [80].	34
Figura 2. 16. Ejemplo de un conjunto de datos no linealmente separables [81]. ..	35

Figura 2. 17. Transformación de los datos de entrada a un espacio de mayor dimensionalidad [81].	35
Figura 2. 18. Esquema de una neurona [82]......	37
Figura 2. 19. Medición de distancia de un punto hacia otros puntos vecinos [82].	39
Figura 3. 1. MAP Quiebrapatas: a) Estructura Interna y Externa de las MAP; b) MAP construida para el experimento; c) MAP enterrada en el suelo de prueba.	40
Figura 3. 2. Terreno con MAPs usado para el trabajo de investigación.....	41
Figura 3. 3. Disposición de las MAP sobre el terreno.	42
Figura 3. 4. Ejemplo de una máscara o kernel diezmo de lado $M = 13$ píxeles y un factor de diezmo de $\zeta = 3$	47
Figura 3. 5. Ejemplo de mejoramiento de contraste térmico en las imágenes: (a) Termograma original con MAP; (b) Termograma procesador por filtro mediana diezmo; (c) Termograma con contraste CTFE.....	48
Figura 3. 6. Parámetros considerados para la obtención de la relación distancia/píxel.....	50
Figura 3. 7. Extracción de ROI sobre una imagen IR. a) Imagen IR; b) 4 ROI con presencia de MAP; c) 4 ROI sin presencia de MAP.	52
Figura 3. 8. Ejemplo de tres ventanas deslizantes consecutivas durante el recorrido de izquierda a derecha (cuadros azul claro y verde), y de arriba abajo (cuadros amarillo y café)... ..	57
Figura 3. 9. Criterio a partir de ROIs vecinas para decidir la clase de la ROI principal.....	58
Figura 3. 10. Primer paso de posprocesamiento en las imágenes: (a) Imagen binaria segmentada entregada por el clasificador; (b) Contorno de detección sobre imagen termográfica.....	58
Figura 4. 1. Demarcación del área de MAP por parte de los clasificadores: a) Demarcación acertada de la MAP clasificador MLP; b) Demarcación errada de la MAP clasificador Naive Bayes.....	68

RESUMEN

En Colombia las minas antipersonal (MAPs) han sido responsables de miles de accidentes atroces sobre la población rural, generando consigo miedo y zozobra constante, lo cual ha conllevado a un constante decrecimiento productivo y cultural sobre estas comunidades afectadas. Dado el proceso de posconflicto en el que se encuentra actualmente el país y la cantidad de MAPs presentes en el territorio, es sumamente necesario realizar la detección y el desarme de dichos artefactos explosivos. Gubernamentalmente, las entidades responsables de realizar el desminado son principalmente las Fuerzas Militares y las Organizaciones Civiles de Desminado Humanitario (OCDH), que emplean regularmente como métodos de detección, los detectores de metales y perros entrenados que, en la práctica, son métodos altamente riesgosos debido a que requieren tener contacto físico cercano con la zona de inspección. Por lo anterior, surge la necesidad de buscar técnicas alternativas de detección de minas que no involucren la interacción física con el terreno a inspeccionar. De este modo, se propuso como alternativa el desarrollo de un sistema de inspección aéreo a través de sensores ópticos IR para detectar a distancia minas antipersonal tipo quiebrapatas, a partir del procesamiento digital de imágenes captadas bajo el principio de la inspección termográfica pasiva del suelo, para tal fin, se usó un Vehículo Aéreo No Tripulado (VANT) equipado con una cámara termográfica y mediante la definición de un protocolo de vuelo y captura se obtuvo una base de datos de imágenes IR, estas se analizaron y procesaron para la configuración e implementación de cinco clasificadores para la demarcación automática de MAPs en imágenes IR, los resultados de detección arrojados son estudiados, concluyendo en alcances y limitaciones del sistema propuesto.

Palabras claves: MAPs, imágenes termográficas, clasificadores y detección.

ABSTRACT

In Colombia, antipersonnel mines (MAPs) have been responsible for thousands of atrocious accidents on the rural population, generating fear and constant anxiety, which has led to a constant decrease in production and culture in these affected communities. Given the post-conflict process that the country is currently in and the number of MAPs present in the territory, it is extremely necessary to detect and disarm these explosive devices. Governmentally, the entities responsible for carrying out demining are mainly the Military Forces and Civil Humanitarian

Demining Organizations (OCDH), which regularly use metal detectors and trained dogs as detection methods, which, in practice, are highly risky methods. because they require close physical contact with the inspection area. Due to the above, there is a need to search for alternative mine detection techniques that do not involve physical interaction with the terrain to be inspected. In this way, the development of an aerial inspection system through IR optical sensors was proposed as an alternative to remotely detect antipersonnel mines of the leg-breaker type, based on the digital processing of images captured under the principle of passive thermographic inspection of the soil, For this purpose, an Unmanned Aerial Vehicle (UAV) equipped with a thermographic camera was used and by defining a flight and capture protocol, an IR image database was obtained, these were analyzed and processed for configuration and implementation. of five classifiers for the automatic demarcation of MAPs in IR images, the detection results obtained are studied, concluding on the scope and limitations of the proposed system.

Keywords: MAPs, thermographic images, classifiers and detection.

1 INTRODUCCIÓN

Las minas antipersonal (MAPs) son artefactos explosivos diseñados para atacar contra la humanidad de una persona, causando múltiples heridas de las que se derivan lesiones musculares, amputaciones de extremidades y, en el peor de los casos, el fallecimiento de las víctimas; su uso es muy común por diversos grupos terroristas y se calcula que hay más de 110 millones de minas repartidas en más de 64 países, las cuales afectan a 26 mil personas cada año [1]. En Colombia las cifras son desalentadoras: las MAP afectan aproximadamente a mil personas por año, más que en cualquier otro país, lo que lo hace el sexto lugar en el mundo con más víctimas hasta la fecha (11,769), y también uno de los principales países en donde existe un sinnúmero de zonas minadas que aún no se han logrado localizar, y que abarcan un estimado de entre 20 y 99 km² [2]. Es tal el impacto de esta problemática en nuestro país que, de los 1101 municipios existentes, en 515 se han presentado accidentes con MAP, siendo los más afectados Vistahermosa (Meta), Tame (Arauca), Tumaco (Nariño), San Vicente del Caguán (Caquetá) y Tarazá (Antioquia) [3].

Las MAP estándar son dispositivos costosos y difíciles de obtener, por lo que los grupos al margen de la ley han optado por su fabricación artesanal. Por ello, existe una gran cantidad de tipos de MAP que varían en su composición, cantidad de explosivo, mecanismos de activación y profundidad de instalación; pero las que suelen ser más comunes en Colombia son las MAP tipo *quiebrapatas*, siendo también las que mayor daño causan a la víctima por ser las más superficiales. Para proteger a la población y evitar que más personas se vean afectadas por este flagelo, el estado demanda alternativas de solución al problema de detección de zonas que puedan estar minadas con estos artefactos para su posterior desarme.

Los métodos más efectivos y comunes para la detección requieren de un contacto físico cercano con la zona a evaluar, lo que pone en riesgo la vida de los involucrados durante esta labor. Aunque existen métodos que permiten la evaluación a distancia como los *Detectores de Metales* (MD) o los *Radares de Penetración Terrestre* (GPR), el éxito de su detección está ligado al tipo y a la profundidad de la MAP. Por otro lado, está en desarrollo el uso de la Termografía Infrarroja como método de Ensayo No Destructivo (END) para la detección de MAP, basándose en la diferencia térmica que se produce entre las minas y el suelo. Sin embargo, la mayoría de los trabajos que han planteado este objetivo se han desarrollado bajo condiciones experimentales controladas o de laboratorio y, por

tanto, los resultados entregados pueden diferir de manera importante a lo que ocurriría en una situación real en campo.

Por lo anterior, se plantea la siguiente pregunta de investigación: ¿cómo detectar minas antipersonal tipo *quiebrapatas*, enterradas en suelo natural, mediante el análisis de imágenes termográficas aéreas? En este contexto, se propone seguir con el estudio de la Termografía como método de detección de minas artesanales, tipo *quiebrapatas*, bajo condiciones de evaluación mucho más cercanas a la realidad. Adicionalmente se propone utilizar un *Vehículo Aéreo No Tripulado* (VANT) para que sobrevuele un área de interés y realice la adquisición de imágenes IR del terreno con la cámara a bordo.

Acorde a lo anterior, este trabajo de investigación busca desarrollar un sistema de detección automático de MAP *quiebrapatas* a partir del análisis de imágenes termográficas aéreas de un suelo arenoso con vegetación limitada. Además, se espera que este trabajo contribuya al fortalecimiento de la línea de investigación en procesamiento de imágenes térmicas al interior del grupo PSI, y brinde un aporte importante al estado del arte del tema a nivel internacional.

Para resolver el problema propuesto se definió un objetivo general y cuatro objetivos específicos que se indican a continuación:

Objetivo General

Desarrollar un sistema para la detección de minas *quiebrapatas*, a partir del análisis de imágenes termográficas aéreas de un suelo arenoso y con vegetación limitada.

Objetivos Específicos

- Conformar la base de datos de las imágenes termográficas aéreas del suelo arenoso y con vegetación limitada.
- Implementar una técnica de realce de contraste térmico de imágenes termográficas, que mejore la detectabilidad de minas *quiebrapatas* en suelos arenosos y con vegetación limitada.
- Implementar una técnica de reconocimiento de patrones para la detección automática de minas *quiebrapatas* a partir de las imágenes termográficas.

- Determinar los alcances y limitaciones del sistema implementado para la detección de minas *quiebrapatas* en suelos arenosos y con vegetación limitada.

En el presente libro, en su capítulo 2, se exponen trabajos de investigación referentes, detallando las diferentes técnicas y metodología propuestas para la detección de minas antipersonal, seguido de esto, se muestra la fundamentación teórica y los métodos empleados en el desarrollo del trabajo, abarcando sobre una revisión de los tipos de minas existentes, métodos tradicionales para su detección, conceptos fundamentales de la termografía, la técnica de mejoramiento de contraste térmico CTFF en imágenes y una breve revisión conceptual sobre máquinas de aprendizaje. En el capítulo 3 se describe el diseño metodológico desarrollado, en donde se detalla la solución dada al problema planteado. Luego, en el capítulo 4 se procede a explicar los resultados obtenidos de implementar cinco máquinas de aprendizaje y una discusión de ellos. Finalmente, en el capítulo 5 se registran las conclusiones obtenidas del desarrollo de este proyecto y se proponen diversos trabajos futuros que podrían complementarlo.

2 MARCO REFERENCIAL

En el presente capítulo se aborda el panorama investigativo a nivel global sobre las distintas metodologías de detección de minas, las técnicas implementadas, ventajas, desventajas y resultados en que llegan, luego se abarca en la explicación de la morfología y tipos de minas antipersonales artesanales en Colombia, métodos de detección de minas, análisis termográfico, técnica de mejoramiento de contraste térmico CTFF y máquinas de aprendizaje.

2.1 ANTECEDENTES

En la literatura se pueden encontrar múltiples trabajos relacionados con la temática de detección de minas, empleando diversas técnicas. La Figura 2.1 muestra la tendencia en las publicaciones mundiales relacionadas haciendo uso de la herramienta Scopus, donde se observa un interés por parte de la comunidad científica en los últimos 25 años con respecto a la temática de investigación.




Figura 2. 1. Tendencia de la investigación sobre detección de Minas Antipersonal [4].

Estados Unidos se presenta como el país con el mayor número de publicaciones referentes al tema de investigación, seguido de Japón y China. En Latinoamérica también se reportan resultados relacionados sobre la temática, en Colombia existen

42 publicaciones, pero en ninguna de estas se emplea la termografía como método de detección, por lo tanto, resulta una oportunidad novedosa para generar investigación y proponer métodos no invasivos basado en el análisis Infrarrojo del suelo, y ajustados a las condiciones locales. En la Figura 2.2 se muestran los países líderes en publicaciones con respecto al tema de investigación.




Figura 2. 2. Países líderes en publicaciones de investigación sobre detección de Minas Antipersonal [4].

Las principales técnicas de detección usadas en la literatura son mediante: Radars de Penetración Terrestre (GPR), Detectores de Metales (MD), cámaras Multiespectrales e Infrarrojas; en las dos primeras se emplea el principio de la radiación electromagnética, mientras que las restantes, se enfocan en el análisis de imágenes en diferentes bandas espectrales.

Dentro de las investigaciones consultadas, en donde se utilizan Radars de Penetración Terrestre se tienen las reportadas en [5-16], cabe resaltar, que los métodos con GPR son más propicios para la detección de minas enterradas a más de 10 cm de profundidad, mas no para minas más superficiales como las tipo *quiebrapatas*, la cual es objeto de investigación de esta propuesta, además la inspección sobre el suelo debe ser lo más cercana posible, aumentando el porcentaje de riesgo en la detección, las investigaciones afines usando Detectores de Metales se encuentran en [17-20], este método es conveniente para la detección de minas metálicas y superficiales, y, como es de esperarse, deficiente para minas con ninguna o poca constitución de metales. Por otro lado, el Análisis de Imágenes

Multiespectrales también constituye una opción interesante y aún en desarrollo para la detección de minas. Entre los trabajos más destacados están [21-24], y es llamativo que su desarrollo, aunque inició en la década de los noventa, se estancó y ha vuelto a resurgir, seguramente como consecuencia de la baja en los precios de este tipo de dispositivos ópticos. Los resultados de detección arrojados por este método van desde el 70% de acierto, pero su masificación se dificulta por su costo aún poco asequible. Existen otras técnicas invasivas y menos comunes, como la Resonancia en Cuadrupolo (NQR) [25], la radiación de rayos X [26] y el uso de vibración acústica y presión de agua [27] y [28].

En lo que respecta a trabajos de investigación centrados en el análisis Infrarrojo, en [29] se propone una metodología que consiste en rociar agua fría sobre el suelo antes de realizar la adquisición de imágenes IR, lo cual se realiza a partir de las 9:00 horas, y la captura se hace en un intervalo 15 minutos, facilitando la medición del gradiente de temperatura resultante entre el suelo y el artefacto. Por otro lado, en [30] se utilizó una serie de imágenes Infrarrojas de onda media (MWIR), que son segmentadas a partir del algoritmo de mapas autoorganizados (SOM); los resultados reportados mostraron una detección del 93% y una tasa del 24% de falsas alarmas. En [31] se ejecuta un experimento de termografía activa con excitación por microondas para realizar la detección de minas terrestres no metálicas sobre arena, se hizo el calentamiento de la zona durante 10 minutos y mediante una cámara de termovisión, se adquirió una secuencia de 600 termogramas, mediante una metodología propuesta se garantizaba un calentamiento uniforme sobre el área determinada; todo el desarrollo se realizó bajo un enfoque de laboratorio como se muestra en la Figura 2.3.




Figura 2.3. Experimento de termografía activa para la detección de MAP propuesta por [31].

En [32] se hace la detección de MAP a partir de la fusión de la información provista por una cámara de espectro visible, una cámara Infrarroja y GPR; se hace la extracción de características de las imágenes de fusión resultantes, para entrenar una Red Neuronal Probabilística (PNN) y posteriormente validar su rendimiento de detección.

Los trabajos precedentes realizan las capturas ubicando la cámara en una posición fija, pero también se ha abordado el uso de Vehículos Aéreos No Tripulados (VANT) para la captura de las imágenes en conjunto con métodos de detección anteriormente mencionados. Por ejemplo, en [33] se utiliza un Quadcopter equipado con una cámara IR y un detector de metales, que realiza un vuelo a 1 metro de distancia del suelo, y un sistema GPS y GSM para enviar los resultados de la inspección. En [34] se utiliza un dron equipado con una cámara IR que captura imágenes a 1 metro de altura sobre el suelo en un área de 1 metro cuadrado durante varios ciclos diurnos (entre las 6:00 y 21:00 horas), y se extrajeron los perfiles térmicos que permiten evaluar los diferenciales térmicos producidos por el calentamiento del sol; adicionalmente, se argumenta que la termografía infrarroja es la técnica que permite identificar gran variedad de MAPs, incluyendo las de tipo artesanal y no metálicas que son indetectables con otros métodos, gracias al comportamiento térmico que exhibe el material explosivo, común en todas las MAP (Figura 2.4).



Figura 2. 4. Sistema de Inspección termográfico mediante un dron propuesto por [40].

En conclusión, aunque existen una gran variedad de técnicas y métodos utilizados para realizar detección de MAP, el enfoque del uso de termografía infrarroja es la de mayor proyección para la detección de un abanico más amplio de tipos de MAPs; muchos de los trabajos fueron probados en ambientes controlados de laboratorio, mientras que los restantes se basan en un análisis más profundo sobre los

fenómenos térmicos que involucran la inspección del suelo [35] [36]. Sin embargo, en la mayoría no implementan algoritmos de aprendizaje para la detección automática, con lo cual se puede incrementar la detectabilidad de las MAPs.

En las Tabla 2.1 y 2.2 se recolectan los trabajos encontrados en la literatura que aportaron significativamente a este trabajo de investigación, en la primera se precisan las técnicas de detección, características del experimento y la precisión, mientras que en la segunda tabla se exponen investigaciones con relación al uso de VANTs para la detección de MAPs.

Referencia	Técnica de detección	Procesamiento	Características	Ítem de sensado	Precisión
[37]	Redes neuronales artificiales (ANN), Maquinas de Vectores de Soporte (SVM), Árboles de Decisión (DT) y k-vecinos más cercanos (kNN); y un Método de Aprendizaje Profundo: Redes Neuronales Convolucionales (CNN).	Extracción de Regiones de interés (ROI) sobre las imágenes	Momentos Estadísticos de primer y segundo orden.	Cámara Quest Condor3 VNN-618 y Cámara FLIR T440bx	97%
[38]	Árboles de Decisión	Se aplicó FFT a los datos del dominio del tiempo y se tomaron los datos del espectro en el rango entre 400 y 450 kHz.	Espectrales	NQR	86%
[39]	-	Técnicas SAR (Radar de Apertura Sintética) para enfocar	imagen GPR del radar de pulso UWB	El radar de onda continua de frecuencia escalonada (SFCW) que transmite radiación electromagnética	-
[40]	-	Cada espectro se procesó mediante la normalización de recuentos totales y el efecto del flujo de neutrones evitó la fluctuación.	Espectrales	Generador de neutrones D-T y detectores BGO	-
[41]	Redes Neuronales Artificiales (ANN)	-	Los gráficos de presión de contacto de la superficie de la arena fueron las entradas de RNA y las características de las minas terrestres fueron los resultados deseados.	Modelo de Elementos Finitos	95%
[42]	-	Señal modelada como una suma de sinusoides amortiguados exponencialmente	Espectro de una señal NQR promedio	Tecnología de detección de resonancia de cuadrupolo nuclear (NQR)	-
[43]	-	Relación entre la amplitud máxima promedio de SAR (Imax) y el rango de la muestra de disco de acero enterrada en el interior	Imágenes SAR de alta resolución	Radar de Apertura Sintética	-
[44]	Regresión logística y Maquinas de Vectores de Soporte (SVM)	Factor de inflación de la varianza	Distancias, densidad de población, pendiente de colina, elevación	Datos geográficos y de desarrollo social	-
[45]	Máquina de Vectores de Soporte (SVM)	Descriptor de histograma de borde (EHD), Log-Gabor (LG), Histograma de gradientes orientados para GPR (gprHOG) y Descriptores de borde espacial (SED)	Cubo de datos GPR	Radar de Penetración Terrestre (GPR)	-
[46]	Máquina de Vectores de Soporte (SVM)	Normalización de datos GPR	Una matriz tridimensional que representa tres tipos de datos ; Escaneo A, Escaneo B y Escaneo C.	Radar de Penetración Terrestre (GPR)	89.24%
[47]	-	Normalización, De convolución y Enfoque	Los hologramas de microondas grabados digitalmente contienen información detallada sobre el tamaño y la forma de los objetos enterrados dentro de la profundidad efectiva de penetración de la señal.	Antena de Radar holográfica	-
[48]	Redes Neuronales Artificiales (ANN), Maquinas de Vectores de Soporte (SVM) y K-medias	Método de Prony y Normalización de características	Señales de Minas Terrestres reflejadas	Radar de Penetración Terrestre (GPR)	99.94%
[49]	Máquinas de Vectores de Soporte (SVM)	Proceso de dirección transversal	Histograma de Gradiente Orientado (HOG)	Radar de Penetración Terrestre (GPR)	95%
[50]	Descomposición de valores singulares (SVD), Conjunto de rango bajo y disperso (JLRS), Representación de rango bajo (LRR), Método de multiplicadores de dirección alterna (ADMM).	PCA, análisis robusto de componentes principales (RPCA), representación de rango bajo	Las señales recogidas por el sistema de radar a lo largo de la dirección transversal o descendente	Radar de Penetración Terrestre (GPR)	97.9%
[51]	-	Control de tiempo, resta promedio, transformada de Fourier, y Enfoque	Imágenes del subsuelo	Radar de Penetración Terrestre (GPR) a bordo de un UAV	-
[52]	-	El producto de imagen de radar final, hecho de la combinación de ocho imágenes RCS procesadas con ángulo azimutal completo de 360°	Imágenes SAR	Radar de apertura sintética (SAR) a bordo de un UAV	-
[53]	Análisis discriminante de Mahalanobis (MDA), el algoritmo del vecino más cercano k (k-NN), SVM y análisis discriminante cuadrático (QDA).	El suavizado posterior a la clasificación se aplica a las etiquetas de clase generadas por los clasificadores a través de un filtro mayoritario de 3 x 3. Reducción de dimensiones. Filtrado espacial	Imágenes térmicas infrarrojas (IR).	Cámaras ATOM 1024 IR y FLIR T 650 SC	100%
[54]	Detección y clasificación de IED en función del análisis de imágenes IRT	Técnica de segmentación basada en la extracción de regiones de transición (TRE) y Filtro morfológico	Imágenes térmicas infrarrojas (IR) basado en la diferencia de nivel de gris (GLD)	Cámara IR	92%
[55]	-	De convolución (o desenfoco de imagen)	Imágenes infrarrojas pasivas	Cámara IR Cedip Titanium 530 LW F/2 (telururo de mercurio y cadmio – MCT)	-
[56]	Redes Neuronales Artificiales (ANN)	Técnicas de Regulación y Normalización	Imágenes IT	Fotodetector IR QuantumWell (QWIP), con una banda espectral en el rango de 8 a 9 m	80-100%
[57]	Método de búsqueda aleatoria, clasificador LVQ-dist, clasificador Naive Bayes	Calibración y corrección de movimiento y Transformación de perspectiva	Secuencia de imágenes polarimétricas	Imágenes medidas con una cámara infrarroja polarimétrica.	75%

Tabla 2. 1. Trabajos de investigación precisando técnicas, metodología y resultados en el detección de MAPs.

Referencia	Técnica de detección	Tipo de Mina	Metodología	Altura de detección	Vehículo
[58]	Sistema de Magnetómetro	Minas Terrestres Antipersonal	Red Neuronales Convolucionales (CNN)	-	-
[59]	Radar de Penetración Terrestre (GPR)	Minas Terrestres Antipersonal de Metal	Conjunto de dos módulos de radar PulsOn P440	1 m	-
[60]	Sistema de Magnetómetro	Minas Antipersonal Metálicas (M16)	Filtro de Paso Bajo Gaussiano	1 m	Construido por el autor 1m x 1m x 0.7m de Tamaño, Peso de 5Kg (incluyendo Baterías)
[61]	Sensores Infrarrojos Térmicos y Multiespectrales ligeros	Minas Terrestres Antipersonal Dispersables (PFM-1)	Red Neuronales Convolucionales (CNN)	-	-
[62]	Radar de Penetración Terrestre (GPR)	Minas Terrestres Antipersonal de Metal	-	1 m	Propuesto para la inspección con drones
[63]	Radar de Penetración Terrestre (GPR)	Minas Terrestres Antipersonal de Metal	Técnicas de Radar de Apertura Sintética (SAR)	-	Construido por las autores (Basado en Raspberry Pi)
[64]	Radar de Apertura Sintética (SAR)	Minas Terrestres Antipersonal de Metal	Técnicas de Radar de Apertura Sintética (SAR)	2,5 m a 4,5 m	Versión personalizada de un dron DJI Matrice 600 Pro
[65]	Radar de Penetración Terrestre (GPR)	Minas Terrestres Antipersonal de Metal	Radar de Onda Continúa Modulada en Frecuencia (FMCW)	2,5 m	DJI Matrice M600 Pro
[34]	Imágenes Térmicas	Minas Terrestres de Metal	-	1 m	Phantom 4 Pro
[66]	Radar de Penetración Terrestre (GPR)	Minas Terrestres Antipersonal de Metal	Técnicas de Radar de Apertura Sintética (SAR)	3 m a 5 m	Construido por las autores (Basado en Raspberry Pi)
[67]	Radar de Penetración Terrestre (GPR) ligero y diseñado a la medida y un método novedoso para el vuelo autónomo a baja altitud llamado Backstepping+DAF	Minas Terrestres Antipersonal de Metal	Controlador backstepping+DAF (DAF: Función de Aceleración Angular deseada)	0,5 m	Hexacóptero llamado Asctec Firefly
[68]	Radar de Penetración Terrestre (GPR)	Minas Terrestres Antipersonal de Metal	Generador de Impulsos Monociclos y Antena de Banda Ultra ancha (UWB)	-	-
[33]	Cámara IR y Detector de Metal	-	GPS para rastrear la ubicación de la mina y la ubicación detectada transmitida mediante un módulo GSM.	1 m	Multiwii v2.5
[69]	Sistema Operativo Robótico (ROS)	Minas Terrestres Antipersonal	ROS	1 m	Drone AR Parrot 2.0

Tabla 2. 2. Trabajos de investigación en detección de MAPs usando VANT.

2.2 MARCO TEORICO

2.2.1 Minas Antipersonal (MAPs)

Las MAPs son artefactos explosivos diseñados exclusivamente para herir, incapacitar o matar personas. En Colombia se han identificado una gran variedad de minas antipersonal de las cuales, más del 90% son de fabricación artesanal, es decir, utilizan materiales de fácil adquisición en mercados locales, incluyendo el material explosivo, compuesto frecuentemente por nitrato de amonio (80%), aserrín fino (15%) y aluminio en polvo (5%) [70].

Existe una gran variedad de MAPs, en su gran mayoría, elaboradas de manera artesanal por los grupos al margen de la ley, ver Figura 2.5. De acuerdo con [70] [71], entre las más comunes se destacan:



Figura 2. 5. Diferentes Minas Antipersonal Artesanales usadas en Colombia: a) Mina Quiebrapatatas, b) Mina Abanico, c) Mina Cumbo pequeño, d) Mina Sombrero pequeño, e) Mina Quiebrapatatas Química, f) Mina Cilindro, g) Mina Cumbo, h) Mina sombrero Chino [72].

A. Mina Quiebrapatatas

Es el tipo de mina más común en Colombia, y por tanto, las que más víctimas cobran. Esta mina se entierra para que explote al ser pisada, y como consecuencia, la persona afectada muera o sufra lesiones que conlleva a amputaciones de miembros. En su fabricación se utilizan tubos de PVC, jeringa, alambre conductor, batería de 9 V, detonador eléctrico, explosivo, fragmentos de metal y en ocasiones pedazos de vidrio.

B. Mina Abanico

Su composición se realiza a partir de lámina galvanizada, brea, metralla y otro tipo de explosivo. Recibe el nombre de abanico porque al activarse son varios los escenarios de daños que puede dejar en la víctima.

C. Mina Cumbo

Tiene un efecto devastador similar al tipo cajón, pero ésta es instalada en las ramas de los árboles para que, al activarse, ya sea por presión o por movimiento, la metralla incorporada se expanda con un mayor radio de acción.

D. Mina Sombrero Chino

El nombre de este tipo de explosivo improvisado tiene que ver con que su forma es similar al de un sombrero camboyano. Tiene la misma composición del tipo abanico, y también se activa por presión, tensión o movimiento; la única diferencia es la forma, mientras que la abanico es triangular, la sombrero chino es cilíndrica.

E. Mina de Costal

Está compuesta por un costal de fique, de donde proviene su nombre, anfo y metralla, se activan a través de un sistema eléctrico, es económica y fácil de armar.

F. Mina tipo Camándula

Entre las diferentes minas antipersonales, es la que tiene mayor poder destructor. Está compuesta por cordón detonante, lámina galvanizada y explosivo. Cuando se activan se producen una serie de explosiones conjuntas que ocasionan graves daños a las víctimas.

G. Mina Cajón

Es la más utilizada por los grupos armados ilegales en carreteras o trochas, porque tienen un efecto enormemente destructor al activarse. Como su nombre lo indica, su estructura está hecha con madera y en su interior se ubica una lámina metálica en ángulo que facilita la acumulación de gases.

2.2.2 Métodos de detección de Minas Antipersonal (MAPs)

A continuación se hace una breve descripción de los métodos de detección más comunes que se emplean para realizar la detección de MAPs.

A. Detector de Metales (MD)

Los Detectores de Metales (Figura 2.6) miden la perturbación de una emisión de campo electromagnético, causado por la presencia de objetos metálicos en el suelo. Una gran desventaja de este sensor es que cada pieza metálica desencadena una alarma. La gran cantidad de falsas alarmas hace que la tarea de detección de minas terrestres sea lenta y costosa [73].



Figura 2. 6. Detector de Metales para la detección de MAPs [74].

B. Radar de Penetración Terrestre (GPR)

Los GPR (Figura 2.7) emiten ondas de radio sobre el suelo y analizan las señales de retorno producidas por reflexiones de discontinuidad de la constante dieléctrica. Se han convertido en una forma alternativa de detectar minas terrestres en grandes áreas desde una distancia de separación segura. El principal inconveniente del GPR es que las irregularidades en el suelo (por ejemplo, raíces, rocas) pueden producir falsas alarmas. Adicionalmente, su rendimiento es sensible a interacciones complejas entre el material de revestimiento de la mina, la textura del suelo y la humedad. Otra limitación es la detección de minas poco profundas, por lo que el reflejo en la superficie del suelo enmascara la respuesta de tales minas [73].




Figura 2. 7. Radar de Penetración Terrestre para la detección de MAPs [75].

C. Cámaras Infrarrojas (IR)

Este es un método de detección térmico (Figura 2.8) que se basa en el hecho de que las variaciones de temperatura diurna en áreas cercanas a las minas terrestres difieren de las áreas circundantes. Mediante un estímulo de energía (puede ser de diferente naturaleza), estas temperaturas se pueden inducir, pero corriendo el riesgo de una detonación accidental de estos artefactos. El rendimiento de IR se ve afectado por factores como las condiciones climáticas, el tamaño de las minas terrestres y su composición [73].




Figura 2. 8. Cámaras IR para la detección de MAPs [72].

2.2.3 Medición Termográfica

El ensayo de termografía constituye una situación compleja, esta complejidad tiene varios orígenes: la naturaleza física misma de la medición por la cámara, la complejidad del objeto observado (llamado “sistema”), la existencia de transferencias de calor entre el sistema y el medioambiente que lo rodea, y la existencia de otras posibles fuentes de calor. Una parte de estas transferencias pueden estar bajo el control del operador (caso de la termografía activa) o totalmente independientes a él (caso de la termografía pasiva). Por tal razón la medición termográfica es un acto entre tres actores: 1) el operador, en ensayo pasivo o activo con su sistema para realizar la termografía (cámara, sincronizador, lámparas etc.), 2) el sistema observado, 3) el medioambiente o entorno. Estas interrelaciones aparecen en la Figura 2.9, de la cual se destaca el hecho que la naturaleza de estas es térmica, implicando todos los modos de transferencias de calor (radiación, convección y conducción) y la producción de fuentes de calor de diferentes naturalezas. Para obtener un diagnóstico termográfico confiable se debe de tener en cuenta las siguientes consideraciones: 1) información acerca de la cámara y de sus características metrológicas, 2) información referente a la constitución del sistema observado y del medioambiente (estructuras, materiales, propiedades), 3) un mínimo de conocimientos en transferencia de calor [76].




Figura 2. 9. Los actores del acto termográfico y los fenómenos físicos que intervienen en la medición [76].

A. Detectores Infrarrojos

Hoy en día, casi todas las cámaras infrarrojas contienen detectores cuyo conjunto es denominado FPA (Focal Plane Array, es decir arreglo de plano focal). El número de detectores define el tamaño de las imágenes (número de píxeles). Hay dos tipos de detectores: los detectores cuánticos, generalmente refrigerados, y los microbolómetros, no refrigerados (ver Figura 2.10). Los primeros son foto detectores acoplados a un sustrato que genera la salida eléctrica de la lectura del píxel (ROIC, *Read-Out Integrated Circuit*). La tasa de actualización puede ser elevada (centenares de Hz - cuadros por segundo). Los segundos son termómetros: cuando un fotón llega, es detectado por el detector mediante un cambio de su temperatura, lo cual hace que la conductividad del material cambia, monitorizándose a través del cambio de una intensidad de corriente de referencia que circula por el dispositivo. El receptor debe estar aislado térmicamente del ROIC y ser eléctricamente conductivo. El hecho de trabajar basándose en un efecto foto conductivo limita la tasa de actualización generalmente a 25 Hz [76].




Figura 2. 10. Los dos tipos de detectores infrarrojos [76].

B. Análisis de la medición Termográfica

Cualquiera sea el tipo de detector, la cámara genera una señal relacionada a la energía radiada que se recibe, la cual, si se considera el sistema observado totalmente aislado del medioambiente, depende de su temperatura superficial (suponiendo el cuerpo opaco). En el caso más general esta dependencia puede ser una función complicada de la longitud de onda, de la temperatura, de la dirección con la cual se enfoca. Generalmente, se considera que se puede definir una emisividad media independiente de la longitud de onda (cuerpo negro y cuerpos

grises). En este caso, se hace la calibración con un cuerpo negro extendido y se aplica la emisividad idónea. Si la forma del sistema es tridimensional hay que tener en cuenta la influencia del ángulo bajo el cual la cámara lo apunta (ver Figura 2.11). Hay procedimientos para tener en cuenta esta variable [76].




Figura 2. 11. Indicatrices de emisión del cuerpo negro, del cuerpo gris y de los dos tipos de materiales (dieléctricos y metálicos) [76].

C. Características de una cámara infrarroja

Las principales características de una cámara infrarroja son: la sensibilidad térmica, la precisión, la resolución espacial y la frecuencia de la imagen.

Sensibilidad térmica o NETD: La sensibilidad térmica, llamada NETD (Noise Equivalent Temperature Difference, es decir ruido equivalente a la menor temperatura detectable), es muy importante para aplicaciones de END. En efecto, cuanto más bajo es el NETD mejor se puede detectar un contraste térmico significativo observable emergiendo por sobre el ruido del sistema.

El NETD de las cámaras bolométricas son del orden de 50 -100 mK y el de las cámaras con detectores cuánticos refrigerados alcanzan un poco menos de 20 mK. Por tal razón se recomienda la utilización del último tipo de cámara cuando una gran sensibilidad es necesaria.

Precisión: Es la medida de cuán precisa es la temperatura medida de un objeto con relación a su temperatura aparente. Casi todas las cámaras actuales alcanzan

precisiones de $\pm 2^{\circ}\text{C}$ o $\pm 2\%$ para los rangos más extendidos. Conocer esta precisión es importante para la END por termografía pasiva.

Resolución Espacial: Se la denomina IFOV (Instantaneous Field of View – Campo de visión instantáneo). Se expresa en miliradians y se trata del área cubierta por un sensor remoto en un determinado momento. Depende del tamaño del detector y de la lente. Esta característica es importante en END cuando se trata de descubrir defectos de tamaño reducido.

Frecuencia de la imagen: Las imágenes en tiempo real tienen tasas de actualización de centenares de Hz (cuadros por segundos). Es el caso de las cámaras con matriz de detectores cuánticos refrigerados. Además, muchas cámaras actuales ofrecen la posibilidad de reducir el tamaño de las imágenes (*windowing*) permitiendo al mismo tiempo aumentar la tasa de actualización, alcanzando varios millares de Hz. Esta característica es importante cuando el sistema observado es un buen conductor del calor, lo que implica tiempos característicos muy breves [77].

2.2.4 Compensación Térmica de Fondo mediante Filtrado (CTFF)

La idea tras este método de Contraste Térmico consiste en tratar de distinguir y extraer de manera automática el fondo de la imagen de entre los posibles defectos que contrasten con aquél. En los termogramas obtenidos de una inspección de Termografía IR activa el fondo está constituido por la superficie sana del material, razón por la cual el mismo fondo contendrá entonces la información sobre el calentamiento no uniforme. Puesto que dicha información se corresponde con una frecuencia espacial bastante baja, un filtrado pasa-bajo selectivo podría aislar la componente del calentamiento de fondo, con la ventaja de hacerlo basado exclusivamente en la información de intensidad de los píxeles, y no en la definición a priori de parámetros intrínsecos del material.

Un tipo de filtrado bastante común en la eliminación de detalles espurios o ruido impulsional en una imagen preservando casi intacta la información de baja frecuencia espacial, es obviamente el filtro mediano; sin embargo, la propuesta se fundamenta en emplear el filtro mediano con el fin de extraer el perfil de calentamiento de fondo, para lo cual se hace necesario asumir que los posibles defectos constituyen los detalles principales a eliminar de la imagen original. Dentro

del método se propone una estrategia para reducir el tiempo de ejecución que demandaría normalmente una máscara de filtro mediana tan grande.

A continuación, se detallan los pasos de la metodología propuesta a la que se le ha denominado *Compensación Térmica de Fondo mediante Filtrado (CTFF)*.

A. Inicialmente se extraen de una secuencia termográfica completa todas las imágenes capturadas *justo después* de que la excitación de calor llega a la superficie del material, y posteriormente se les resta una de las imágenes frías (no incluidas en la secuencia de trabajo por estar *antes* del pulso de calor), tanto para mejorar preliminarmente el contraste como para atenuar patrones de ruido de la cámara infrarroja. Si se tienen píxeles defectuosos de fabricación, también deben corregirse en las imágenes como paso previo; igualmente debe considerarse el filtrado de la secuencia para atenuar el ruido aleatorio presente en las imágenes. En consecuencia, la imagen de referencia I_{Ref} , de requerirse para cualquier cálculo posterior, sería la primera imagen de la secuencia resultante.

B. La máscara para el filtro mediana debe cumplir con el requerimiento primordial de cubrir un área suficientemente extensa de la imagen como para filtrar el perfil de calentamiento no uniforme, eliminando los contrastes abruptos causados por posibles defectos; sin embargo, un tamaño considerable puede distorsionar el propio perfil de fondo, además de demandar un tiempo de ejecución que puede llegar a ser exagerado.

Como alternativa a la selección manual del tamaño de la máscara del filtro mediana, de tal manera que se evite la distorsión del perfil de fondo, se desarrolló un procedimiento que utiliza una máscara de lado M_0 igual a una fracción de $1/r$ del lado menor de la imagen, comenzando con $r = 1$, para filtrar la imagen de referencia I_{Ref} , posteriormente se reduce la máscara haciendo $r = 2$, se filtra la misma imagen y se evalúa la diferencia entre los valores filtrados de intensidad en el pixel p_{Qmax} cuyo valor sea el máximo sobre la imagen I_{Ref} sin filtrar.

El proceso sigue incrementando a r con cada iteración hasta que la diferencia entre los últimos dos valores filtrados de intensidad en p_{Qmax} sea menor o igual al 10% del valor original de p_{Qmax} .

C. Con el fin de disminuir este tiempo, conservando a la vez el tamaño de la región procesada durante el cálculo del valor mediana, se optó por una estrategia en la que no todos los píxeles de la región se tienen en cuenta: cada píxel considerado

está separado de sus vecinos analizados por una cantidad de ζ píxeles en las cuatro direcciones cardinales (ver Figura 2.12).




Figura 2. 12. Ejemplo de máscara modificada para el filtro mediana diezmado [78].

D. Puesto que la máscara pretende abarcar una región suficientemente grande de la imagen, los bordes de esta tienden a afectarse. Por tanto, para mejorar los resultados de la aplicación del filtro hacia los bordes, se propone también como alternativa al procedimiento, una extrapolación de éstos de tal manera que al expandirlos se intente conservar la tendencia del comportamiento térmico a medida que se avanza hacia la periferia de cada imagen. El procedimiento al que se le ha denominado *expansión lineal de bordes* consiste en tomar una porción adecuada de la periferia, o *marco base*, de cada termograma. Para los cuatro lados del marco se calcula el promedio de intensidad de los píxeles en cada fila paralela a los bordes correspondientes de la imagen; se ajustan entonces los promedios obtenidos en cada lado del marco a una recta mediante regresión lineal, a partir de la cual, por extrapolación, se estiman los promedios que exhibirían los píxeles ubicados en las filas más allá de los bordes, si aquéllas se consideraran o existieran. Las relaciones de proporción entre los promedios extrapolados y los valores de los píxeles del borde la imagen, permiten estimar los valores de los píxeles de la región expandida.

E. Una vez realizado el filtrado de mediana sobre cada uno de los termogramas de la secuencia original, se obtiene la *secuencia de calentamiento de fondo* que correspondería a la evolución del calor en el espécimen bajo evaluación, si éste no presentara defectos internos; es decir, que llamando a esta secuencia de calentamiento como $S^C(t)$, y siendo f y c el total de filas y columnas de cada imagen respectivamente, se tiene:

$$S^C(t) = F_{med}^{M,\zeta} \left(I_t(p_{ij}) \right), \forall i, j, \quad \text{con } i = 1 \dots f, j = 1 \dots c \quad (\text{Ecu. 2.1})$$

Siendo $S_{i,j}(t)$ y $S_{i,j}^C(t)$ las secuencias originales y de calentamiento de fondo evaluadas en un pixel de coordenadas (i,j) para el tiempo t , se tiene la ecuación 2.2 para el contraste absoluto:

$$\Delta T_{CTFF}(t) = S_{i,j}(t) - S_{i,j}^C(t), \forall i, j, t \quad (\text{Ecu. 2.2})$$

Ejecutando la ecuación anterior para todas las imágenes (barriendo t) se obtiene finalmente la secuencia compensada. La Figura 2.13 primero compara un ejemplo de perfil espacial de un termograma original con el perfil de calentamiento de fondo obtenido después del filtro mediana descrito, y luego muestra el resultado de la resta entre los dos. En el mismo sentido, la Figura 2.14 resume el procedimiento de compensación, donde a un termograma con algunos defectos, se le resta la imagen estimada sin defectos para el mismo t (termograma de calentamiento de fondo), obteniendo el termograma compensado (contraste térmico) [78].




Figura 2.13. a) Comparación entre un perfil original, y el perfil de calentamiento de fondo estimado; b) Resultado de la resta entre los dos perfiles anteriores [78].




Figura 2. 14. Comparación entre un termograma original, su perfil de calentamiento de fondo estimado y su versión contrastada [78].

2.2.5 Máquinas de Vectores de Soporte (SVM)

Las SVM conforman hiperplanos que separan los datos de entrada en dos subgrupos que poseen una etiqueta propia. En medio de todos los posibles planos de separación de las dos clases etiquetadas como $\{-1,1\}$, existe solo un hiper-plano de separación óptimo, de forma que la distancia entre el hiperplano óptimo y el valor de entrada más cercano sea máxima (maximización del margen) con la intención de forzar la generalización de la máquina que se esté construyendo. Aquellos puntos o ejemplos sobre los cuales se apoya el margen máximo son los denominados vectores de soporte (ver Figura 2.15) [79].




Figura 2. 15. Hiperplano de separación lineal considerando el máximo margen [80].

Si se supone que las clases están separadas completamente por un hiperplano d-dimensional.

$$w \cdot x + b = 0 \quad (\text{Ecu. 2.3})$$

El problema de separación consiste entonces en determinar el hiper-plano de tal manera que: $w \cdot x + b \geq 1$ para ejemplos positivos y $w \cdot x + b \leq -1$ para ejemplos negativos.

Dado que la SVM encuentra el plano con el máximo margen, este se puede encontrar minimizando $\frac{1}{2} \|w\|^2$

$$\min_{w,b} \phi(w) = \frac{1}{2} \|w\|^2 \quad (\text{Ecu. 2.4})$$

El hiper-plano óptimo de separación puede ser encontrado entonces minimizando la ecuación 2.4 bajo la restricción de la ecuación 2.5 para separar correctamente los datos.

$$y_i(x_i \cdot w + b) - 1 \geq 0, \forall i \quad (\text{Ecu. 2.5})$$

Este es un problema de programación cuadrática para el cual se usan técnicas estándar como los multiplicadores de Lagrange [80].

Si los datos de entrada no son linealmente separables como se muestra en la Figura 2.16, existe la posibilidad de transformar los datos a un espacio ζ de mayor dimensión (el espacio de características) en el que los puntos si pueden ser separados por un hiper-plano. Para ello, se utiliza una función ϕ , tal que:

$$\phi: \mathbb{R}^d \rightarrow \zeta, \quad x \rightarrow \phi(x) \quad (\text{Ecu. 2.6})$$




Figura 2. 16. Ejemplo de un conjunto de datos no linealmente separables [81].

La función ϕ , como muestra la Figura 2.17, mueve los datos de entrada que no son linealmente separables a un espacio de mayor dimensión donde sí se podrá encontrar un hiperplano que los separe. La frontera de decisión resultante en el espacio de entrada ya no será lineal y vendrá dada por otro tipo de función que puede ser polinómica, gaussiana, entre otras [81].




Figura 2. 17. Transformación de los datos de entrada a un espacio de mayor dimensionalidad [81].

El teorema de Cover enuncia que si la transformación es no lineal y la dimensionalidad del espacio de características es lo suficientemente alta entonces

el espacio de entrada puede ser transformado en un espacio de características en donde la probabilidad de separación lineal entre los patrones sea alta. Esta transformación no lineal se lleva a cabo de manera implícita a través de las funciones Kernel que representan el producto vectorial en el espacio de características [80].

Las funciones Kernel más utilizadas son:

Función Polinómica:

$$K(x, x') = (x^T x' + c)^d \quad c \in \mathbb{R}, d \in \mathbb{N} \quad (\text{Ecu. 2.7})$$

Función Gaussiana:

$$K(x, x') = \exp\left(\frac{-\|x - x'\|^2}{2\sigma^2}\right) \quad (\text{Ecu. 2.8})$$

Función Sigmoide:

$$K(x, x') = x^T \cdot x \quad (\text{Ecu. 2.9})$$

2.2.6 Redes Neuronales Artificiales (RNA)

Las Redes Neuronales Artificiales (RNA) son modelos bioinspirados empleados para la clasificación, el reconocimiento de patrones, la segmentación de imágenes, entre otras más aplicaciones.

El elemento básico de procesamiento de una RNA es la neurona y se representa por el esquema ilustrado en la Figura 2.18, las entradas $x_1, x_2, \dots, x_n$ tienen conexión a la neurona k y estas señales a su vez se multiplican por los pesos sinápticos w_k . El producto de las entradas con los pesos se suma con un bias b_k y finalmente son operadas con una función de activación φ que permite limitar la amplitud de salida de la neurona [80].




Figura 2. 18. Esquema de una neurona [80].

Matemáticamente el modelo de la RNA se expresa a partir de la ecuación 2.10, la sumatoria del producto de las pesos w_{kj} por las entradas x_j son u_k , en la ecuación 2.11 el termino b_k es el bias que permite disminuir o incrementar la función de activación ϕ dependiendo si es positiva o negativa y y_k corresponde a la señal de salida de la neurona [80].

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad \text{Ecu. 2.10}$$

$$y_k = \phi(u_k + b_k) \quad \text{Ecu. 2.11}$$

La función de activación ϕ permite definir el tipo de salida de la neurona, entre las más comunes se tienen:

Función de activación Identidad:

$$f(x) = x \quad \text{Ecu. 2.12}$$

Función de activación Escalón Binario:

$$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0 \end{cases} \quad \text{Ecu. 2.13}$$

Función de activación Sigmoidal:

$$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}} \quad \text{Ecu. 2.14}$$

2.2.7 Redes Bayesianas

Dados dos sucesos aleatorio A y B cuyas probabilidades se denotan por $P(A)$ y $P(B)$, respectivamente, donde $P(B) > 0$, se supone que se conocen las probabilidades a priori $P(A)$, $P(B)$ y la probabilidad condicionada del suceso B dado el A , ósea $P(B|A)$. Con la información anterior se calcula la probabilidad a posteriori del suceso A dado el suceso B , es decir $P(A|B)$. usando la ecuación 2.15

$$P(A|B) = \frac{P(A, B)}{P(B)} = \frac{P(A)P(B|A)}{P(B)} \quad Ecu. 2.15$$

Al trabajar con variables unidimensionales o multidimensionales se tiene que el teorema de Bayes se formula de la siguiente manera:

$$P(Y = y|X = x) = \frac{P(Y = y)P(X = x|Y = y)}{\sum_y P(Y = y)P(X = x|Y = y)} \quad Ecu. 2.16$$

El clasificador bayesiano es conocido como *Naive Bayes*, el cual asume independenciancia entre las variables usadas para realizar la clasificación, facilitando la representación del conocimiento[82].

2.2.8 K-Vecinos más cercanos (KNN)

Es un clasificador de aprendizaje supervisado no paramétrico, que utiliza la proximidad para hacer clasificaciones o predicciones sobre la agrupación de un punto de datos individual. Si bien se puede usar para problemas de regresión o clasificación, generalmente se usa como un algoritmo de clasificación, partiendo de la suposición de que se pueden encontrar puntos similares cerca uno del otro.

Para determinar qué puntos de datos están más cerca de un punto de consulta determinado, será necesario calcular la distancia entre el punto de consulta y los otros puntos de datos. Estas métricas de distancia ayudan a formar límites de decisión, que dividen los puntos de consulta en diferentes regiones (Figura 2.19) [80].




Figura 2. 19. Medición de distancia de un punto hacia otros puntos vecinos [80].

Entre las medidas de distancia más comunes utilizadas por el clasificador KNN se tienen:

Distancia Euclidiana:

$$d(x, k) = \sqrt{\sum_{i=1}^n (k_i - x_i)^2} \quad Ecu. 2.17$$

Distancia Manhattan:

$$d(x, k) = \sum_{i=1}^m |x_i - k_i| \quad Ecu. 2.18$$

Distancia Minkowski:

$$d(x, k) = \left(\sum_{i=1}^m |x_i - k_i| \right)^{1/p} \quad Ecu. 2.19$$

3 DISEÑO METODOLÓGICO

En esta sección se describe la metodología utilizada para la implementación del sistema de detección de Minas Antipersonal tipo Quiebrapatatas (MAP) a partir del análisis de imágenes termográficas aéreas de un terreno. Este apartado inicia con la descripción del montaje realizado para la experimentación, y finaliza con la descripción de la metodología utilizada para la detección de MAPs a partir de imágenes termográficas aéreas. Esta última cubre todos los aspectos relacionados de la implementación de un sistema de visión artificial.

3.1 DISEÑO DEL EXPERIMENTO

En la investigación presentada en [83] se detalla la estructura de las MAP utilizadas por los grupos armados en Colombia, y cómo emular la construcción de MAP utilizando: un cilindro externo de PVC de 10,2 cm de alto y 7,62 cm de diámetro (Figura 3.1a), una jeringa de 5 mL como mecha de bomba para cada artefacto, 20 g de clavos y 400 g de carbón de antracita (Figura 3.1b). El carbón de antracita puede usarse para reemplazar el TNT, pues tal como lo resume en la Tabla 3.1, ambos tienen características térmicas similares, sobre todo en el calor específico y la conductividad térmica. Sin embargo, el carbón de antracita podría ser más difícil de identificar, ya que no emite naturalmente gases como lo hace el TNT; gases que absorben radiación, lo que favorece la detección en el espectro IR [84]; por lo tanto, la detección de MAPs con carbón de antracita sólo puede centrarse en sus propiedades térmicas y morfológicas, pero agregan seguridad a la experimentación en campo.




Figura 3. 1. MAP Quiebrapatatas: a) Estructura Interna y Externa de las MAP; b) MAP construida para el experimento; c) MAP enterrada en el suelo de prueba.

<i>Propiedades</i>	<i>TNT</i>	<i>Carbón de Antracita</i>
Densidad (g/cm ³)	1.56	1.37
Calor específico (J/gK)	1.37	1.26
Conductividad Térmica (W/mK)	0.26	0.23

Tabla 3. 1. Propiedades térmicas del TNT y del carbón de antracita.

Las MAPs construidas se dispusieron dentro de un terreno (en Anexos se incluye la caracterización del suelo) con vegetación escasa dentro del campus de la Universidad del Valle y formando un cuadrado de 10 m de lado. Algunas MAPs se dispusieron sobre el suelo a modo de referencia, y las demás se enterraron a profundidades de 1, 5 y 10 cm. La Figura 3.2 presenta una fotografía del terreno, mientras que la Figura 3.3. resume la disposición y profundidad de las minas en el terreno.



Figura 3. 2. Terreno con MAPs usado para el trabajo de investigación.




Figura 3. 3. Disposición de las MAP sobre el terreno.

3.2 METODOLOGÍA PARA LA DETECCIÓN DE MAP A PARTIR DE IMÁGENES IR

La exposición de la metodología se organizará con base en las etapas que deben abordarse en un sistema de reconocimiento de patrones según [80], estas son: **Sensado, Preprocesamiento, Extracción y Selección de Características, Entrenamiento, Clasificación y Posprocesamiento**. Cada una de estas etapas se detalla a continuación.

3.2.1 Etapa de Sensado

La etapa de **Sensado** recae en los dispositivos utilizados para capturar imágenes termográficas aéreas del suelo; por lo tanto, involucra la cámara y el UAV empleados, así como la estrategia de navegación durante la captura.

A. Dispositivos de captura y condiciones ambientales adecuadas

Para la adquisición de imágenes termográficas aéreas del terreno se utilizó una cámara DJI Zenmuse XT dispuesta sobre un UAV marca DJI Matrice 100. Las Tablas 3.2 y 3.3 presentan las especificaciones de la cámara y del UAV, respectivamente. Note que la cámara IR seleccionada cuenta con una resolución que permite la captura de imágenes en un amplio rango de altura para la inspección del suelo, su banda espectral cubre las longitudes de onda larga (7.5 a 13.5 μm) en donde la absorción atmosférica es mínima; y que el peso de la cámara puede ser soportado por el UAV, pues es inferior a la carga máxima soportada de 900 gramos.

<i>Píxeles</i>	<i>Rango espectral (μm)</i>	<i>Rango angular de vibración</i>	<i>Sensibilidad térmica (mK)</i>	<i>Peso (g)</i>
336x256	7.5 – 13.5	$\pm 0.03^\circ$	<50	270

Tabla 3. 2. Especificaciones de la cámara termográfica.

<i>Tipo</i>	<i>Carga útil de tiempo de vuelo (min)</i>	<i>Velocidad máxima de ascenso (m/s)</i>	<i>Velocidad máxima de descenso (m/s)</i>	<i>Resistencia al viento (m/s)</i>	<i>Altura máxima de vuelo (m)</i>	<i>Temperatura de funcionamiento ($^\circ\text{C}$)</i>	<i>Carga máxima soportada (g)</i>
Cuacoptero	20	5	4	10	120	-10 a 40	900

Tabla 3. 3. Especificaciones del UAV.

Antes de iniciar la captura se tuvieron en cuenta las condiciones climáticas, ya que pueden incidir en la inspección de un terreno con MAP mediante imágenes térmicas [82]; así, se realizaron en días soleados sin nubosidad ni lluvia, en el intervalo entre las 17:00 a las 18:00 horas del día siguiendo la recomendación dada en [34], pues en dicho intervalo se presentan mayores diferencias térmicas entre el suelo y la MAP. Por lo anterior, se realizó una primera captura después de 10 días consecutivos de tiempo seco (febrero 13), una segunda después de 4 días consecutivos de lluvia (febrero 24) y una última después de 4 días de tiempo seco (marzo 3) con el propósito de analizar el efecto que podría tener la humedad del suelo, teniendo en cuenta que la humedad es un parámetro que, en exceso, tiende a afectar negativamente la inspección termográfica [34].

En todos los casos, se midieron las variables ambientales previas a la captura, y corresponden a los datos de la Tabla 3.4.

<i>Fecha de Adquisición</i>	<i>Temperatura ambiente ($^\circ\text{C}$)</i>	<i>Radiación solar (W/m^2)</i>	<i>Humedad relativa del aire (%)</i>	<i>Velocidad del viento (m/s)</i>
Febrero 13, 2020	26.84	122.98	65.33	2.54
Febrero 24, 2020	24.58	113.42	78.75	1.12
Marzo 3, 2020	26.15	123.15	65.34	2.08

Tabla 3. 4. Condiciones ambientales para cada experimento de inspección.

En [85] se especifica el rango de valores recomendados de temperatura ambiente y la velocidad del viento para la inspección desde un UAV, capturando imágenes tanto en el espectro visible como el infrarrojo, estos son:

- Temperatura ambiente en un rango entre 26 y 30 °C, para favorecer la difusión térmica de la MAP sobre la superficie.
- Velocidad del viento entre 3 y 5 m/s, mayores rangos de velocidad al indicado afectarían importantemente la medición termográfica, debido a que el aire cercano a la superficie tiene la misma temperatura que el objeto medido, esto como resultado del intercambio de calor, por lo tanto, las corrientes de aire alteran este equilibrio de temperatura [86].

Es importante señalar que durante la captura realizada el 24 Febrero del 2020, la temperatura ambiente estuvo un poco más de 1 °C por debajo respecto a lo recomendado por [85], pero se mantuvo por ser una variación leve y así analizar su incidencia en el sistema de detección de MAPs.

Adicional a estas dos variables ambientales, se registró la radiación solar y la humedad relativa del aire, ya que podían resultar significativas a la hora de analizar los resultados del experimento termográfico, y por lo tanto, han sido registradas por otros experimentos termográficos como el reportado en [82].

B. Estrategia de navegación

Para la captura se posicionó el dron en la parte central de cada una de las nueve zonas y, en el caso que en la zona haya una MAP, este también corresponde de forma aproximada al centro de la ubicación de la MAP. Posteriormente el dron fue comandado para elevarse a un metro de altura y permanecer en la misma ubicación respecto a las otras coordenadas, y se adquirieron imágenes termográficas en formato TIF cada segundo durante 11 segundos. La decisión de tomar varias imágenes a esta altura se fundamentó primero, en que esta altura corresponde a la elegida para el sistema de inspección de este trabajo, y segundo, a que el dron presentaba inestabilidad posicional a causa del viento, lo que sumado al ruido térmico inherente a una cámara, permitía tener variabilidad en la base de datos para la identificación de minas.

Aunque como ya se mencionó, el presente trabajo se enfoca en la detección de MAPs a 1 metro de altura, se incluyeron capturas a otras alturas, de manera que posteriormente se pudiera validar los límites en la detección del sistema propuesto respecto a esta variable; como resultado, la base de datos quedó constituida como se resume en la Tabla 3.5:

Altura de Adquisición	Fecha de adquisición	Número de Imágenes IR									Subtotal
		Mina a 1 cm			Mina superficial		Sin Mina	Mina a 5 cm		Mina a 10 cm	
		Zona 1	Zona 2	Zona 3	Zona 4	Zona 5	Zona 6	Zona 7	Zona 8	Zona 9	
1 m	Febrero 13, 2020	11	11	11	11	11	11	11	11	11	297
	Febrero 24, 2020	11	11	11	11	11	11	11	11	11	
	Marzo 3, 2020	11	11	11	11	11	11	11	11	11	
2 a 10 m	Febrero 13, 2020	9	9	9	9	9	9	9	9	9	243
	Febrero 24, 2020	9	9	9	9	9	9	9	9	9	
	Marzo 3, 2020	9	9	9	9	9	9	9	9	9	
Subtotal		180			120		60	120		60	540

Tabla 3. 5. Banco de imágenes IR adquiridas según fecha de adquisición, altura de adquisición y zona.

Una vez se adquieren las imágenes, a ellas se les realiza un preprocesamiento que incluye el filtrado de ruido y el mejoramiento del contraste, ambos con el objetivo de que las minas puedan detectarse con mayor precisión.

3.2.2 Etapa de Preprocesamiento

Para la reducción de ruido intrínseco propio de la cámara, se les aplicó a las imágenes termográficas un filtrado tipo mediana con un kernel de tamaño 3 x 3 píxeles. El filtro mediana es el más apropiado para no perder información de bordes, ya que su aplicación en imágenes reduce el efecto borroso en comparación a otros filtros [87], mientras que el tamaño de la máscara fue seleccionado de manera heurística, al encontrar que se lograba la supresión de ruido, alterando de forma mínima los bordes entre regiones que contengan minas enterradas y el suelo, que favorecerían la detección de MAPs.

Posteriormente, con el propósito de mejorar el contraste térmico de las imágenes, lo que se espera contribuya a la detección de MAPs, se seleccionó la técnica de Compensación Térmica de Fondo mediante Filtrado (CTFF) [78], metodología concebida y desarrollada en el grupo de investigación PSI. La justificación para su elección se basa en las siguientes razones:

- El contraste CTFF no depende de ningún modelo de propagación del calor en el medio bajo inspección. Esta cualidad cobra significativa relevancia en una situación como la difusión del calor en el suelo, por ser ésta un fenómeno

bastante complejo ante la cantidad de variables involucradas, y la falta absoluta de uniformidad en sus características físicas.

- El contraste CTFF no depende de ningún parámetro físico intrínseco del material inspeccionado. Esta cualidad se relaciona con la característica anterior, y hace que sea viable su aplicación en cualquier tipo de material; en el caso de estudio, en cualquier tipo de suelo.
- El contraste CTFF desacopla la información térmica de fondo de aquella asociada a la presencia de MAPs que pretenden detectarse. Esta cualidad corresponde al objetivo principal de la técnica, y se basa en la hipótesis de que la información global de una determinada imagen ofrece variaciones de baja frecuencia espacial, mientras que los detalles más localizados corresponden a variaciones de mayor frecuencia. Para este trabajo, aunque resulte menos evidente que en aplicaciones de Ensayo No-Destructivo, el suelo va a presentar generalmente una distribución térmica no-uniforme que puede afectar la ejecución y los resultados de una metodología de clasificación.

La técnica CTFF se basa en la aplicación de un filtro mediana para recuperar la información de baja frecuencia, reduciendo al mínimo cualquier remanente que corresponda a información de detalle en las imágenes, haciendo uso de las propiedades estadísticas de la mediana [88]. Para ello, el filtro que recupera la información de fondo puede expresarse matemáticamente como:

$$F_{med}^{M,\zeta} \left(I(p_{i,j}) \right) = \text{mediana} \left(I(p_{i \pm n\zeta, i \pm n\zeta}) \right) \text{ con } n = 0, 1, 2, \dots, \frac{M-1}{2\zeta} \text{ y } M \text{ impar} \quad (\text{Ecu. 3.1})$$

Donde $F_{med}^{M,\zeta} \left(I(p_{i,j}) \right)$ corresponde a un filtro mediana, centrado en el píxel $p_{i,j}$ de la imagen I que usa una máscara espacial 2D cuadrada de M píxeles de lado y una distancia ζ entre píxeles que correspondería a un factor de diezmado. Con el diezmado es posible hacer que el resultado del filtro para cada píxel $p_{i,j}$ de la imagen se vea influenciado por una región bastante grande (de M píxeles de lado), ejecutándose en el mismo tiempo que si se usara una máscara de M/ζ píxeles de lado. Gráficamente, un ejemplo de máscara o kernel de este tipo con un ζ igual a 3, es el que se presenta en la Figura 3.4. En la práctica, el factor de diezmado se calcula a partir del número efectivo de píxeles por cada lado de la máscara de filtrado; este valor, que por defecto es de 5 (píxeles en azul de la Figura 3.4), puede ser modificado por el usuario.




Figura 3. 4. Ejemplo de una máscara o kernel diezmo de lado $M = 13$ píxeles y un factor de diezmo de $\zeta = 3$.

De otra parte, al usar máscaras de filtrado muy grandes, los bordes de las imágenes tienden a afectarse demasiado, de manera que el filtrado anterior va a acompañado de un procedimiento de expansión de bordes que intenta prolongar la tendencia en la evolución de las intensidades de la imagen hacia su periferia, de manera que cada imagen se expande de adaptativamente para poder acomodar las máscaras grandes del filtrado mediana, sin afectar considerablemente los bordes de las imágenes [88].

Por último, el mejoramiento de contraste propiamente dicho se obtiene mediante la resta entre cada imagen I antes de filtrar y su versión filtrada con el filtro mediana diezmo $F_{med}^{M,\zeta}(I(p_{i,j}))$. Aunque hay varios modos de realizar el contraste CTFF, para este proyecto se usó la versión absoluta de la ecuación 3.2.

$$\Delta I_{CTFF} = I - F_{med}^{M,\zeta}(I) \quad (\text{Ecu. 3.2})$$

Con el fin de reducir la probabilidad de aumentar el ruido en la imagen contrastada como consecuencia de la resta de dos imágenes con ruido, la técnica CTFF permite realizar un post-suavizado adicional para atenuar el ruido remanente, aplicando un segundo filtro mediana de tamaño 3x3.

El resultado de la imagen contrastada resaltará la diferencia térmica entre las anomalías que se pretende detectar y el suelo. En la Figura 3.5 se presenta en a)

un termograma con presencia de MAP sin mejoramiento de contraste, en b) el termograma procesado por el filtro mediana con un diezmado de 10, y en c) el resultado de aplicar mejoramiento del contraste mediante la técnica CTFF; en donde se puede apreciar una mayor uniformidad en el fondo de la imagen y un mayor contraste entre la región con MAP y el suelo.




Figura 3. 5. Ejemplo de mejoramiento de contraste térmico en las imágenes: (a) Termograma original con MAP; (b) Termograma procesador por filtro mediana diezmado; (c) Termograma con contraste CTFF.

Los parámetros usados para aplicar la técnica de fueron los siguientes:

- **Dimensión de máscara o kernel (M)** = 41 píxeles (6 veces menor al lado menor de las imágenes originales).

- **Factor de diezmado ($\hat{f}$)** = 10 (para el número efectivo de píxeles por lado de la máscara de filtrado, establecido por defecto).
- **Tratamiento de los bordes:** reconstrucción matemática de la periferia.
- **Post-suavizado:** sí.

Los valores de los dos primeros parámetros se obtuvieron a través de un algoritmo automático, incluido como opción dentro de la técnica CTFF, que intenta estimar los mejores valores de dimensión y de diezmado de la máscara del filtrado de mediana para obtener un mayor contraste térmico al final de la aplicación de la técnica. Este algoritmo de ajuste automático se basa en la reducción iterativa de la dimensión de la máscara, empezando con el máximo tamaño posible (lado de la máscara igual al lado menor de las imágenes de la secuencia) y una imagen de referencia seleccionada por el usuario, para después aplicar el filtro de mediana en cada iteración sobre la imagen resultante del filtrado en la iteración anterior; antes de continuar con la iteración siguiente, se mide el producto del valor máximo de la raíz del error cuadrático de la imagen y la raíz de su error cuadrático medio. Esta exploración iterativa termina cuando el diezmado se considera muy pequeño (≤ 3). Finalmente, la dimensión y el diezmado estimados se escogen de aquella iteración en la que se consigue un valor mínimo del producto mencionado; en caso de que no se consiga el valor mínimo, se escogen los valores correspondientes a la menor dimensión de máscara considerada durante la exploración iterativa.

Posterior a la aplicación de esta técnica de mejoramiento de contraste, de las 198 imágenes adquiridas a 1 metro de altura con mina enterrada (ver Tabla 3.5) se descartaron mediante inspección visual aquellas con la menor uniformidad térmica de fondo alrededor de la MAP, quedando un subgrupo de 136 imágenes (ver Anexos). Se conformó también otro conjunto con estas 136 imágenes sin que se les aplicara contraste térmico, para posteriormente evaluar su efecto en el reconocimiento de MAPs.

3.2.3 Etapa de Extracción y Selección de Características

En esta etapa se utilizaron regiones de interés (ROIs) y, para determinar su tamaño, se obtuvo la relación distancia/píxel deducida a partir de los parámetros descritos en la Figura 3.6, donde h es la altura de adquisición en metros desde el suelo, q es la dirección (ya sea horizontal o vertical), θ_q es el ángulo de la cámara de visión en grados y l_q es la longitud del suelo en metros, estas dos últimas en la dirección de q (horizontal o vertical según sea el caso).




Figura 3. 6. Parámetros considerados para la obtención de la relación distancia/píxel.

Los parámetros anteriores se relacionan trigonométricamente a partir de la tangente (ecuación 3.3), y resulta en la ecuación 3.4 cuando se despeja la longitud del suelo en metros en el campo de visión de la cámara (l_q):

$$\tan\left(\frac{\theta_q}{2}\right) = \frac{l_q/2}{h} \quad (\text{Ecu. 3.3})$$

$$l_q = 2h \tan\left(\frac{\theta_q}{2}\right) \quad (\text{Ecu. 3.4})$$

De las especificaciones técnicas de la cámara IR [89] se extrae que el ángulo de visión (θ_q) horizontal es de 49.1° y el vertical de 37.4° , y la altura de vuelo es conocida para todas las imágenes.

La longitud del suelo en metros en el campo de visión de la cámara (l_q), que se obtiene a partir de la ecuación 3.4, puede llevarse a longitud/píxel (L_{pq}), al dividir l_q por la longitud del suelo en píxeles dq , dando la ecuación 3.5.

$$L_{pq} = \frac{2h \tan\left(\frac{\theta_q}{2}\right)}{dq} \quad (\text{Ecu. 3.5})$$

Dado que el tubo de PVC usado en la construcción de MAPs es 3,81 cm, se puede establecer el área transversal estimada de la MAP (A_T) mediante la ecuación 3.6, dando como resultado 45,6 cm².

$$A_T = \pi r^2 \quad (\text{Ecu. 3.6})$$

Con esta información se obtienen la longitud/píxel L_{pq} tanto para el eje horizontal como vertical para cada altura de adquisición (Ver Tabla 3.6). A partir de la multiplicación de la razón longitud/píxel en las direcciones horizontal y vertical, se puede estimar el área por píxel en cm² (ver cuarta columna). Finalmente, se puede obtener la cantidad de píxeles equivalentes en la imagen correspondiente a la MAP, al dividir el área estimada de la MAP (A_T) entre el valor del área por píxel de la cuarta columna.

<i>Altura de adquisición (m)</i>	<i>Longitud/píxel horizontal (cm)</i>	<i>Longitud/píxel vertical (cm)</i>	<i>Área/píxel (cm²)</i>	<i>Área equivalente de MAP (píxeles)</i>
1	0,272	0,264	0,072	635
2	0,544	0,529	0,288	159
3	0,816	0,793	0,647	71
4	1,088	1,058	1,150	40
5	1,359	1,322	1,797	26
6	1,631	1,587	2,588	18
7	1,903	1,851	3,523	13
8	2,175	2,116	4,602	10
9	2,447	2,380	5,824	8
10	2,719	2,644	7,190	7

Tabla 3. 6. Relaciones entre dimensiones espaciales y su correspondencia en píxeles para las diferentes alturas de adquisición de las imágenes térmicas.

Conociendo el área equivalente de MAP en píxeles ya obtenida para cada altura, y contrastándolo con una cualificación del área en la imagen térmica, en las imágenes adquiridas a 1 metro hay un aumento aproximado del 69% del área equivalente, como efecto de la difusión de calor de la MAP sobre el área circundante (suelo), alterando la firma térmica. De este modo, se definió como tamaño de ROI un cuadrado de 16 x 16 píxeles, lo cual corresponde a la cuarta parte del área de la MAP en la firma térmica.

Este procedimiento, puede ser aplicado a otras alturas hasta los 5 metros, dando como resultado la Tabla 3.7. Para alturas superiores, las ROIs dejan de ser regiones y corresponden prácticamente a un píxel o menos.

<i>Altura de adquisición (metros)</i>	<i>Tamaño de la ROI en píxeles</i>
2	8 x 8
3	5 x 5
4	4 x 4
5	3 x 3

Tabla 3. 7. Tamaño de ROI para alturas superiores a 1 metro.

Con el propósito de tener una base de datos balanceada para el entrenamiento, ya que un gran porcentaje de la imagen corresponde al suelo, de cada una de las 136 imágenes con MAPs se extrajeron 8 ROIs, 4 sobre la mina, y 4 sobre el suelo (ver recuadros azules en el ejemplo de la Figura 3.7). Como resultado, la base de datos para entrenamiento queda constituida por un total de 1088 ROIs.




Figura 3. 7. Extracción de ROI sobre una imagen IR. a) Imagen IR; b) 4 ROI con presencia de MAP; c) 4 ROI sin presencia de MAP.

Dado que para el reconocimiento se usarán máquinas de aprendizaje, es necesario extraer características de las ROIs. En [82] se usaron los 4 primeros momentos estadísticos (media, desviación estándar, curtosis y asimetría), así como los valores de intensidad máxima y mínima; mientras que en [90] se sugiere el uso de características de textura: energía, contraste, correlación y homogeneidad, calculando matrices de coocurrencia a 0°, 45°, 90° y 135°.

Etiqueta	Característica
C1	Media
C2	Desviación
C3	Curtosis
C4	Asimetría
C5	Mínimo
C6	Máximo
C7	Contraste 0
C8	Correlación 0
C9	Energía 0
C10	Homogeneidad 0
C11	Contraste 45
C12	Correlación 45
C13	Energía 45
C14	Homogeneidad 45
C15	Contraste 90
C16	Correlación 90
C17	Energía 90
C18	Homogeneidad 90
C19	Contraste 135
C20	Correlación 135
C21	Energía 135
C22	Homogeneidad 135

Tabla 3. 8. Características extraídas por ROI.

Se puede verificar que estas características oscilan entre valores disimiles, unas con grandes valores y otras con pequeños. Estas variaciones suelen afectar negativamente los resultados alcanzados por las máquinas de aprendizaje, pues características con valores altos tienen mayor influencia en las funciones de costo sobre las de valores pequeños durante el aprendizaje; por lo que se aconseja aplicar algún tipo de normalización. Hay varios tipos de normalización que pueden ser aplicados, como la **Estandarización**, el **Escalamiento lineal** ya sea a **[0,1]** o a **[-1,1]**, o el **Escalamiento no lineal Softmax**, estas fueron evaluadas y los mejores resultados de detección de MAP se obtuvieron con el **Escalamiento [0,1]** coincidiendo con lo reportado en [37].

El uso de un número excesivo de características puede incrementar la complejidad de los clasificadores y degradar su rendimiento [80], por lo que a la etapa de extracción de características le suele seguir una etapa de **selección** de

características previo al entrenamiento, de manera que se preserven sólo aquellas que son más discriminantes.

Algunas de las técnicas de ranking de características requieren que éstas sigan una distribución Normal; por lo que se aplicó en primera instancia la evaluación de Gaussianidad de *Lilliefors*, que se basa en la prueba de *Kolmogórov-Smirnov*. La prueba dio como resultado que todas las características a excepción de la última (**C22: Homogeneidad35**) tienen una distribución normal.

Lo anterior significa que es conveniente usar una técnica de ranking que sea independiente de la distribución de las características, como el criterio de *Fisher Discriminant Ratio* (FDR), que puede ser usado para cuantificar el poder discriminante de características entre dos clases. Como resultado se encontró que las cuatro características más relevantes corresponden a: **C6: Máximo**, **C1: Media**, **C5: Mínimo** y **C17: Energía 90**. Note que las tres primeras fueron usadas en [82], mientras que sólo aparece una de textura. Cabe aclarar que la adquisición de imágenes propuesta por [82] se hizo a una altura de 2,1 m sobre el suelo y a 3 m de distancia de la zona de inspección, bajo estas condiciones logró un reconocimiento del 93.8 %.

3.2.4 Etapa de Entrenamiento

Para el **entrenamiento** se decidió usar el 75% de la base de datos balanceada, y el 25% restante para la prueba; la elección de esta proporción obedeció a la baja cantidad de muestras disponibles (1088 ROIs), por lo que no era factible aumentar la proporción de prueba pues afectaría la generalización de los clasificadores.

En [82] se usaron tres clasificadores: Redes Neuronales Artificiales tipo MLP, Máquinas de Vectores de Soporte (SVM) y Naive Bayes, pero usando un conjunto de características diferente al usado en este trabajo, pues no realizaron la etapa de selección de características ni incluyeron características de textura. No se encontraron trabajos que usaran los clasificadores de K-Vecinos más cercanos o de Redes Neuronales tipo RBF para la detección de MAPs. En consecuencia, se decidió evaluar estos cinco clasificadores.

Para cada uno de los clasificadores se realizaron variaciones en sus parámetros, conservando aquel con los mejores resultados en cuanto exactitud y sensibilidad tanto con los datos de entrenamiento como de prueba. Sin embargo, se privilegia la

sensibilidad y los resultados de los datos de prueba. La primera usada comúnmente por los autores para presentar el desempeño de los clasificadores, y la segunda porque resalta la aparición de falsos negativos, es decir, cuando el clasificador indica erróneamente que no hay mina, condición que se penaliza severamente por las implicaciones que podría tener.

Para el entrenamiento de la Red Neuronal Artificial tipo MLP, se usaron funciones de activación *sigmoidal* en todas las neuronas y el algoritmo de aprendizaje de *Levenberg-Marquard*. El número de neuronas en la capa oculta se varió en 1 entre 5 y 30, rango establecido a partir de encontrarse los mejores desempeños en las métricas de sensibilidad y exactitud, de este modo, el mejor resultado se obtuvo con 15 neuronas. Aunque se usaron diferentes características, en [82] también se obtuvo un mejor desempeño con este mismo número de neuronas ocultas, pero en dicho trabajo las funciones de activación fueron *tansing* para la capa oculta y *softmax* para la capa de salida.

En la configuración de la Máquina de Vectores de Soporte (SVM) se utilizó el método de entrenamiento ISDA probando 3 Kernels: Lineal, Polinomial y RBF. Para cada kernel se variaron los parámetros asociados, resultando ser el kernel polinomial de orden 8 el más destacable en función de resultados. En contraposición, en [82] se usó LS como algoritmo de entrenamiento y un kernel sigmoidal.

En cuanto al clasificador Naive Bayes, no hay parámetros independientes que puedan ser ajustados, y por tanto, siempre que se usen los mismos datos de entrenamiento su salida será invariante.

La Red Neuronal Artificial tipo RBF tiene la ventaja sobre el tipo MLP, que sólo debe ajustarse el parámetro *spread*. El mejor resultado se obtuvo para un *spread* de 0,5, y estableciendo una parada de entrenamiento en base a la cantidad de 55 neuronas.

Finalmente, para el clasificador de K-Vecinos más cercanos, el parámetro a ajustar corresponde al número de vecinos que se tendrán en cuenta para la clasificación, se probó desde 2 vecinos hasta 14, encontrándose los mejores resultados con el uso de tres (3) vecinos.

3.2.5 Etapa de Clasificación

La etapa de **Clasificación** parte de los clasificadores ya entrenados de la fase previa, pero ahora, recibirán como entrada todas las ROIs extraídas de las imágenes completas. Por lo tanto, se implementó la técnica de ventana deslizante, en el que la ventana tiene el tamaño de la ROI establecido para cada altura e inicialmente se ubica en el borde superior izquierdo de la imagen y luego se traslada recorriendo toda la imagen. No obstante, las ROIs se solapan en un 75%, ya que este valor permite un balance entre el detalle de demarcación de la zona con MAP y el tiempo de procesamiento; mientras que el solapamiento incide positivamente en el reconocimiento al reevaluar buena parte de una zona, aumenta el tiempo de cómputo, por lo que en caso que el sistema no falle en el reconocimiento de una ventana, el sistema puede recuperarse de este error con otras ventanas aledañas, lo que suele ocurrir cuando la ventana cubre solo una pequeña parte de la mina y afectando solamente el tamaño final de la mina pero alertando de que la zona debe ser inspeccionada con precaución.

La Tabla 3.9 condensa los parámetros usados para la técnica de ventanas deslizantes para la altura de captura de 1 m.

<i>Número de Imágenes utilizadas para clasificación</i>	<i>Dimensión de la ROI (píxeles)</i>	<i>Desplazamiento vertical y horizontal por ROI extraída en clasificación (píxeles)</i>	<i>Cantidad de ROIs extraídas en clasificación por imagen</i>
136	16 x 16	4	4941

Tabla 3. 9. Definición de parámetros utilizados para las ventanas deslizantes cuando la captura de las imágenes se realiza a 1 m de altura.

La Figura 3.8 presenta cinco ventanas deslizantes que se usarían cuando la captura se realice a una altura de 1 m. Considerando que el recorrido se realiza de izquierda a derecha, y desde arriba hasta abajo; la primera corresponde al cuadrado con borde continuo azul, la segunda con borde entrecortado de color azul claro, y la tercera con borde entrecortado verde; una vez se llegue al final derecho, se realiza un el desplazamiento hacia abajo que corresponde al cuadrado entrecortado amarillo, mientras que el cuadrado entrecortado café correspondería al desplazamiento hacia abajo subsecuente al amarillo.




Figura 3. 8. Ejemplo de tres ventanas deslizantes consecutivas durante el recorrido de izquierda a derecha (cuadros azul claro y verde), y de arriba abajo (cuadros amarillo y café).

3.2.6 Etapa de Posprocesamiento

La etapa de **posprocesamiento** consiste en dos pasos. El primer paso busca tener una mayor certeza sobre la decisión de los clasificadores para cada ROI identificada como mina, de esta manera, para asegurar que una ROI es una mina se consideran otras 3 ROIs vecinas y, si al menos 2 de ellas fueron clasificadas también como minas, en consecuencia, la ROI principal bajo inspección es reafirmada como mina. La Figura 3.9 permite identificar las ROIs aledañas (cuadro verde: la primera ROI desplazada a la derecha de la principal, cuadro naranja: la ROI desplazada hacia abajo respecto a la principal, cuadro morado: la ROI desplazada a la derecha y hacia abajo) que fueron usadas para confirmar la presencia de mina en la ROI principal (cuadro azul claro).




Figura 3. 9. Criterio a partir de ROIs vecinas para decidir la clase de la ROI principal.

La Figura 3.10 presenta un ejemplo del resultado de aplicar la anterior estrategia de decisión para la detección de una mina, en a) la mina segmentada y en b) el borde de la mina detectada sobre la imagen original. Note que hay un pequeño desplazamiento a la izquierda y hacia arriba, debido a la dirección en la que se desplazan las ventanas, el cual se compensa con una mayor precisión en la detección. Aunque este desplazamiento podría corregirse usando un mayor número de ROIs, en la parte superior y a la izquierda de la ROI principal, incrementaría bastante el tiempo de cómputo, cuando en cualquier caso se debe trazar un borde de seguridad alrededor de la mina, ya sea para un desminado o para un tránsito seguro por la zona.




Figura 3. 10. Primer paso de posprocesamiento en las imágenes: (a) Imagen binaria segmentada entregada por el clasificador; (b) Contorno de detección sobre imagen termográfica.

Una vez segmentada una MAP (Figura 3.10), es posible descartar áreas detectadas como minas cuando en realidad son parte del suelo (falsos positivos), haciendo uso del conocimiento que se tiene del área real que ocupa una MAP a una altura dada. El área de una MAP fue establecida en la última columna de la Tabla 3.6 (Área equivalente de MAP en píxeles), recordando que se trataba de un valor teórico, y que en las firmas térmicas esta área es mayor, por tanto, puede ser usado directamente como criterio de rechazo.

4 RESULTADOS

El presente capítulo presenta y analiza los resultados obtenidos del sistema de detección de MAPs basado en máquinas de aprendizaje y visión artificial. Se iniciará con un resumen de los resultados obtenidos al implementar cinco clasificadores distintos de reconocimientos de patrones en imágenes termográficas aéreas capturadas a un 1 metro de altura del suelo. De forma complementaria y yendo más allá de los objetivos planteados para este trabajo de investigación, se presentarán resultados exploratorios con imágenes adquiridas a mayores alturas con el objeto de validar las limitaciones de la metodología propuesta.

4.1 RESULTADOS DE CLASIFICACIÓN CON LOS DATOS DE ENTRENAMIENTO Y PRUEBA.

Como se describió en el capítulo anterior, se usaron como entradas de los clasificadores 4 características: valor máximo, media, valor mínimo y energía a 90°. Estos valores se normalizaron linealmente para estar en el rango de 0 a 1, de acuerdo con los datos de la base de datos balanceada usada para el entrenamiento (correspondiente al 75% de las muestras).

Estas características se extrajeron de ROIs de las imágenes preprocesadas (filtradas y contrastadas) que, para el caso de las imágenes capturadas a 1 m, las ROIs tienen un tamaño de 16 x 16. Sin embargo, como se presentará más adelante, también se probó la clasificación que se puede obtener con características extraídas de ROIs de imágenes filtradas pero sin contrastar. Lo anterior se hace para establecer la ventaja que podría tener la aplicación de la técnica de contraste seleccionada (CTFF). Los clasificadores en ambos casos tienen la misma arquitectura.

La Tabla 4.1 presenta los resultados alcanzados para los datos de entrenamiento, usando las métricas de exactitud y de sensibilidad; mientras que la Tabla 4.2 lo hace para los datos de prueba. En todos los casos se puede apreciar que las métricas son más altas cuando se excluye del preprocesamiento el mejoramiento del contraste. Aunque estos resultados no corresponden a lo que se esperaba, se considera una ventaja el requerir menos algoritmos y al mismo tiempo tener métricas para los datos de prueba con valores por encima del 95,2% en la exactitud y del 91.2% en la sensibilidad (sombreado con verde y sin cursiva en la Tabla 4.2). Los anteriores valores fueron los más bajos, pues los más altos se obtuvieron con

SVM y KNN, donde se logró una exactitud del 99,3% y una sensibilidad del 98,5% para los datos de prueba (sombreado con azul oscuro y sin cursiva en la Tabla 4.2).

Clasificador	Resultados para los datos de entrenamiento			
	<i>Muestras contrastadas con CTFF</i>		<i>Muestras sin contraste CTFF</i>	
	<i>Exactitud (%)</i>	<i>Sensibilidad (%)</i>	<i>Exactitud (%)</i>	<i>Sensibilidad (%)</i>
MLP	90,0	83,8	99,4	99,0
SVM	90,6	89,0	99,5	99,5
Naive Bayes	87,5	91,9	98,2	97,5
RBF	90,9	85,0	98,9	97,8
KNN	93,3	93,4	98,9	99,3

Tabla 4. 1. Resultados para los datos de entrenamiento de los cinco clasificadores.

Clasificador	Resultados para los datos de prueba			
	<i>Muestras contrastadas con CTFF</i>		<i>Muestras sin contraste CTFF</i>	
	<i>Exactitud (%)</i>	<i>Sensibilidad (%)</i>	<i>Exactitud (%)</i>	<i>Sensibilidad (%)</i>
MLP	85,3	77,9	98,9	97,8
SVM	87,5	85,3	99,3	98,5
Naive Bayes	86,8	89,0	95,2	91,2
RBF	86,4	80,1	96,3	92,6
KNN	86,4	86,8	99,3	98,5

Tabla 4. 2. Resultados para los datos de prueba de los cinco clasificadores.

En cuanto a los resultados alcanzados usando las imágenes contrastadas, el mejor desempeño se logró con SVM en cuanto a la métrica de exactitud (87,5%), y para Naive Bayes en cuanto a la métrica de sensibilidad (89%) (sombreado con azul oscuro y cursiva en la Tabla 4.2). Si se analizan ambas métricas en conjunto, se puede decir que el mejor clasificador fue aquel con Naive Bayes, pues minimiza los falsos negativos mientras que disminuye menos el 1% en la exactitud respecto a SVM.

En las siguientes secciones se detallan los resultados presentados en las anteriores tablas para cada clasificador, y por tanto, corresponden a las pruebas realizadas sobre la base de datos balanceada usada para el entrenamiento (75%) y prueba (25%).

4.1.1 Resultados de entrenamiento y prueba para el clasificador Perceptrón Multicapa (MLP)

La Tabla 4.3 presenta los resultados de clasificación de las ROIs que hicieron parte de los datos de entrenamiento de una red neuronal MLP; los de la izquierda sobre imágenes contrastadas, y los de la derecha con imágenes sin contrastar. En el primer caso la exactitud fue del 90% mientras que en el segundo el 99,4%; así mismo, mientras que con las imágenes contrastadas se clasificaron erróneamente 66 ROIs como parte del suelo (8,1%), en las imágenes sin contrastar este error ocurrió en cuatro casos (0,5%).

Matriz de Confusión		Clase real		
		ROI Suelo	ROI MAP	Porcentaje
Clase estimada	ROI Suelo	392	66	85,6%
		48,0%	8,1%	14,4%
	ROI MAP	16	342	95,5%
		2,0%	41,9%	4,5%
Porcentaje		96,1%	83,8%	90,0%
		3,9%	16,2%	10,0%

Matriz de Confusión		Clase real		
		ROI Suelo	ROI MAP	Porcentaje
Clase estimada	ROI Suelo	407	4	99,0%
		49,9%	0,5%	1,0%
	ROI MAP	1	404	99,8%
		0,1%	49,5%	0,2%
Porcentaje		99,8%	99,0%	99,4%
		0,2%	1,0%	0,6%

Tabla 4. 3. Matrices de confusión de entrenamiento del clasificador MLP. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.

La Tabla 4.4 presenta los resultados de clasificación de las ROIs que se reservaron para prueba. Al igual que como sucedió con los datos de entrenamiento, se obtuvo una exactitud mayor para las ROIs extraídas de las imágenes sin contrastar (98,9%) frente a un 85,3% cuando se contrastaron. De forma similar, sólo se clasificaron erróneamente 3 ROIs como parte del suelo cuando en realidad son minas en la imágenes sin contrastar, frente a 30 que se presentaron en las ROIs extraídas de las imágenes contrastadas.

Matriz de Confusión		Clase real		
		ROI Suelo	ROI MAP	Porcentaje
Clase estimada	ROI Suelo	126	30	80,8%
		46,3%	11,0%	19,2%
	ROI MAP	10	106	91,4%
		3,7%	39,0%	8,6%
Porcentaje		92,6%	77,9%	85,3%
		7,4%	22,1%	14,7%

Matriz de Confusión		Clase real		
		ROI Suelo	ROI MAP	Porcentaje
Clase estimada	ROI Suelo	136	3	97,8%
		50,0%	1,1%	2,2%
	ROI MAP	0	133	100,0%
		0,0%	48,9%	0,0%
Porcentaje		100,0%	97,8%	98,9%
		0,0%	2,2%	1,1%

Tabla 4. 4. Matrices de confusión de prueba del clasificador MLP. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.

4.1.2 Resultados de entrenamiento y prueba para el clasificador Máquinas de Vectores de Soporte (SVM)

Las SVM fueron uno de los clasificadores con los que se logró la mejor clasificación de las ROIs extraídas de imágenes sin contrastar tanto para las métricas de exactitud como para la sensibilidad. Cuando se usan imágenes contrastadas, las SVMs presentan los mejores resultados en cuanto a la métrica de exactitud.

La Tabla 4.5 presenta los resultados de clasificación de las ROIs que hicieron parte de los datos de entrenamiento de una SVM; los de la izquierda sobre imágenes contrastadas, y los de la derecha con imágenes sin contrastar. En el primer caso la exactitud fue del 90,6% mientras que en el segundo el 99,5%; así mismo, mientras que con las imágenes contrastadas se clasificaron erróneamente 45 ROIs como parte del suelo (5,5%), en las imágenes sin contrastar este error ocurrió en dos casos (0,2%).

Matriz de Confusión		Clase real		
		ROI Suelo	ROI MAP	Porcentaje
Clase estimada	ROI Suelo	376	45	89,3%
		46,1%	5,5%	10,7%
	ROI MAP	32	363	91,9%
		3,9%	44,5%	8,1%
	Porcentaje	92,2%	89,0%	90,6%
		7,8%	11,0%	9,4%

Matriz de Confusión		Clase real		
		ROI Suelo	ROI MAP	Porcentaje
Clase estimada	ROI Suelo	406	2	99,5%
		49,8%	0,2%	0,5%
	ROI MAP	2	406	99,5%
		0,2%	49,8%	0,5%
	Porcentaje	99,5%	99,5%	99,5%
		0,5%	0,5%	0,5%

Tabla 4. 5. Matrices de confusión de entrenamiento del clasificador SVM. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.

La Tabla 4.6 presenta los resultados de clasificación de las ROIs que se reservaron para prueba. Al igual que como sucedió con los datos de entrenamiento, se obtuvo una exactitud mayor para las ROIs extraídas de las imágenes sin contrastar (99,3%) frente a un 87,5% cuando se contrastaron. De forma análoga, sólo se clasificaron erróneamente 2 ROIs como parte del suelo cuando eran minas en la imágenes sin contrastar, frente a 20 que se presentaron en las ROIs extraídas de las imágenes contrastadas.

Matriz de Confusión		Clase real		
		ROI Suelo	ROI MAP	Porcentaje
Clase estimada	ROI Suelo	122	20	85,9%
		44,9%	7,4%	14,1%
	ROI MAP	14	116	89,2%
		5,1%	42,6%	10,8%
	Porcentaje	89,7%	85,3%	87,5%
		10,3%	14,7%	12,5%

Matriz de Confusión		Clase real		
		ROI Suelo	ROI MAP	Porcentaje
Clase estimada	ROI Suelo	136	2	98,6%
		50,0%	0,7%	1,4%
	ROI MAP	0	134	100,0%
		0,0%	49,3%	0,0%
	Porcentaje	100,0%	98,5%	99,3%
		0,0%	1,5%	0,7%

Tabla 4. 6. Matrices de confusión de prueba del clasificador SVM. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.

4.1.3 Resultados de entrenamiento y prueba para el clasificador Naive Bayes

El clasificador Naive Bayes fue el mejor clasificador con el que se logró la mejor clasificación de las ROIs provenientes de imágenes contrastadas, de acuerdo con la métrica de sensibilidad.

La Tabla 4.7 presenta los resultados de clasificación de las ROIs que hicieron parte de los datos de entrenamiento del clasificador Naive Bayes; los de la izquierda sobre imágenes contrastadas, y los de la derecha con imágenes sin contrastar. En el primer caso la exactitud fue del 87,5% mientras que en el segundo el 98,2%; así mismo, mientras que con las imágenes contrastadas se clasificaron erróneamente 33 ROIs como parte del suelo (4,0%), en las imágenes sin contrastar este error ocurrió en diez casos (1,2%).

Matriz de Confusión		Clase real		
		ROI Suelo	ROI MAP	Porcentaje
Clase estimada	ROI Suelo	339	33	91,1%
		41,5%	4,0%	8,9%
	ROI MAP	69	375	84,5%
		8,5%	46,0%	15,5%
	Porcentaje	83,1%	91,9%	87,5%
		16,9%	8,1%	12,5%

Matriz de Confusión		Clase real		
		ROI Suelo	ROI MAP	Porcentaje
Clase estimada	ROI Suelo	403	10	97,6%
		49,4%	1,2%	2,4%
	ROI MAP	5	398	98,8%
		0,6%	48,8%	1,2%
	Porcentaje	98,8%	97,5%	98,2%
		1,2%	2,5%	1,8%

Tabla 4. 7. Matrices de confusión de entrenamiento del clasificador Naive Bayes. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.

La Tabla 4.8 presenta los resultados de clasificación de las ROIs que se reservaron para prueba. Al igual que como sucedió con los datos de entrenamiento, se obtuvo una exactitud mayor para las ROIs extraídas de las imágenes sin contrastar (95,2%) frente a un 86,8% cuando se contrastaron. En cuanto a los falsos negativos, se clasificaron erróneamente 12 ROIs en la imágenes sin contrastar, frente a 15 que se presentaron en las ROIs extraídas de las imágenes contrastadas.

Matriz de Confusión		Clase real		
		ROI Suelo	ROI MAP	Porcentaje
Clase estimada	ROI Suelo	115	15	88,5%
		42,3%	5,5%	11,5%
	ROI MAP	21	121	85,2%
		7,7%	44,5%	14,8%
	Porcentaje	84,6%	89,0%	86,8%
		15,4%	11,0%	13,2%

Matriz de Confusión		Clase real		
		ROI Suelo	ROI MAP	Porcentaje
Clase estimada	ROI Suelo	135	12	91,8%
		49,6%	4,4%	8,2%
	ROI MAP	1	124	99,2%
		0,4%	45,6%	0,8%
	Porcentaje	99,3%	91,2%	95,2%
		0,7%	8,8%	4,8%

Tabla 4. 8. Matrices de confusión de prueba del clasificador Naive Bayes. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.

4.1.4 Resultados de entrenamiento y prueba para el clasificador Red de Base Radial (RBF)

Los resultados con redes neuronales tipo RBF aunque fueron buenos, fueron los más bajos entre los cinco clasificadores implementados.

La Tabla 4.9 presenta los resultados de clasificación de las ROIs que hicieron parte de los datos de entrenamiento de una red neuronal RBF; los de la izquierda sobre imágenes contrastadas, y los de la derecha con imágenes sin contrastar. En el primer caso la exactitud fue del 90,9% mientras que en el segundo el 98,9%; así mismo, mientras que con las imágenes contrastadas se clasificaron como parte del suelo erróneamente 61 ROIs (7,5%), en las imágenes sin contrastar este error ocurrió en nueve casos (1,1%).

Matriz de Confusión		Clase real		
		ROI Suelo	ROI MAP	Porcentaje
Clase estimada	ROI Suelo	395 48,4%	61 7,5%	86,6% 13,4%
	ROI MAP	13 1,6%	347 42,5%	96,4% 3,6%
	Porcentaje	96,8% 3,2%	85,0% 15,0%	90,9% 9,1%

Matriz de Confusión		Clase real		
		ROI Suelo	ROI MAP	Porcentaje
Clase estimada	ROI Suelo	408 50,0%	9 1,1%	97,8% 2,2%
	ROI MAP	0 0,0%	399 48,9%	100,0% 0,0%
	Porcentaje	100,0% 0,0%	97,8% 2,2%	98,9% 1,1%

Tabla 4. 9. Matrices de confusión de entrenamiento del clasificador RBF. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.

La Tabla 4.10 presenta los resultados de clasificación de las ROIs que se reservaron para prueba. Al igual que como sucedió con los datos de entrenamiento, se obtuvo una exactitud mayor para las ROIs extraídas de las imágenes sin contrastar (96,3%) frente a un 86,4% cuando se contrastaron. De forma similar, sólo se clasificaron erróneamente 10 ROIs como parte del suelo en la imágenes sin contrastar, frente a 27 que se presentaron en las ROIs extraídas de las imágenes contrastadas.

Matriz de Confusión		Clase real		
		ROI Suelo	ROI MAP	Porcentaje
Clase estimada	ROI Suelo	126 46,3%	27 9,9%	82,4% 17,6%
	ROI MAP	10 3,7%	109 40,1%	91,6% 8,4%
	Porcentaje	92,6% 7,4%	80,1% 19,9%	86,4% 13,6%

Matriz de Confusión		Clase real		
		ROI Suelo	ROI MAP	Porcentaje
Clase estimada	ROI Suelo	136 50,0%	10 3,7%	93,2% 6,8%
	ROI MAP	0 0,0%	126 46,3%	100,0% 0,0%
	Porcentaje	100,0% 0,0%	92,6% 7,4%	96,3% 3,7%

Tabla 4. 10. Matrices de confusión de prueba del clasificador RBF. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.

4.1.5 Resultados de entrenamiento y prueba para el clasificador K-Vecinos más cercanos (KNN)

El clasificador KNN junto con las SVMs fueron los clasificadores con los que se logró la mejor clasificación de las ROIs extraídas de imágenes sin contrastar, de acuerdo con la métrica de exactitud.

La Tabla 4.11 presenta los resultados de clasificación de las ROIs que hicieron parte de los datos de entrenamiento del clasificador KNN; los de la izquierda sobre imágenes contrastadas, y los de la derecha con imágenes sin contrastar. En el primer caso la exactitud fue del 93,3% mientras que en el segundo el 98,9%; así mismo, mientras que con las imágenes contrastadas se clasificaron erróneamente 27 ROIs como parte del suelo (3,3%), en las imágenes sin contrastar este error ocurrió sólo en tres casos (0,4%).

Matriz de Confusión		Clase real		
		ROI Suelo	ROI MAP	Porcentaje
Clase estimada	ROI Suelo	380 46,6%	27 3,3%	93,4% 6,6%
		28 3,4%	381 46,7%	93,2% 6,8%
	ROI MAP	28 3,4%	381 46,7%	93,2% 6,8%
		28 3,4%	381 46,7%	93,2% 6,8%
Clase estimada	ROI Suelo	402 49,3%	3 0,4%	99,3% 0,7%
		6 0,7%	405 49,6%	98,5% 1,5%
	ROI MAP	6 0,7%	405 49,6%	98,5% 1,5%
		6 0,7%	405 49,6%	98,5% 1,5%
Clase estimada	Porcentaje	93,1% 6,9%	93,4% 6,6%	93,3% 6,7%
		93,1% 6,9%	93,4% 6,6%	93,3% 6,7%
	Porcentaje	93,1% 6,9%	93,4% 6,6%	93,3% 6,7%
		93,1% 6,9%	93,4% 6,6%	93,3% 6,7%

Tabla 4. 11. Matrices de confusión de entrenamiento del clasificador KNN. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.

La Tabla 4.12 presenta los resultados de clasificación de las ROIs que se reservaron para prueba. Al igual que como sucedió con los datos de entrenamiento, se obtuvo una exactitud mayor para las ROIs extraídas de las imágenes sin contrastar (99,3%) frente a un 86,4% cuando se contrastaron. En cuanto a los falsos negativos, sólo se clasificaron erróneamente 2 ROIs en la imágenes sin contrastar, frente a 18 que se presentaron en las ROIs extraídas de las imágenes contrastadas.

Matriz de Confusión		Clase real		
		ROI Suelo	ROI MAP	Porcentaje
Clase estimada	ROI Suelo	117 43,0%	18 6,6%	86,7% 13,3%
		19 7,0%	118 43,4%	86,1% 13,9%
	ROI MAP	19 7,0%	118 43,4%	86,1% 13,9%
		19 7,0%	118 43,4%	86,1% 13,9%
Clase estimada	Porcentaje	86,0% 14,0%	86,8% 13,2%	86,4% 13,6%
		86,0% 14,0%	86,8% 13,2%	86,4% 13,6%
	Porcentaje	86,0% 14,0%	86,8% 13,2%	86,4% 13,6%
		86,0% 14,0%	86,8% 13,2%	86,4% 13,6%

Tabla 4. 12. Matrices de confusión de prueba del clasificador KNN. Izquierda: Muestras contrastadas con CTFF; Derecha: Muestras sin contraste CTFF.

4.2 RESULTADOS DE CLASIFICACIÓN USANDO LA TÉCNICA DE VENTANA DESLIZANTE SOBRE EL TOTAL DE IMÁGENES TERMOGRÁFICAS AÉREAS DEL SUELO SIN CONTRASTAR CAPTURADAS A 1 M DE ALTURA

En este subapartado se presentan y analizan los resultados de aplicar la técnica de ventana deslizante a las 136 imágenes de la base de datos, pero sin contrastarlas, ya que los resultados preliminares evidenciaron que esto contribuye a un mejor reconocimiento de las MAPs. Es importante mencionar que dentro del grupo de 136 imágenes no se incluyen imágenes con minas superficiales, pues no corresponde a un caso real, y además, no constituyen un reto significativo para los clasificadores.

Los resultados que se presentaran a continuación evalúan la efectividad en la localización de la mina, cuando se realizan tres pasos:

- a) La catalogación realizada por los clasificadores para cada ventana deslizante de tamaño 16x16, que da lugar a 4.941 ventanas deslizantes por imagen.
- b) La clasificación de cada ventana deslizante analizando en conjunto la catalogación previa de ventanas deslizantes contiguas.
- c) Descartando regiones cuyo tamaño sea inferior al mínimo esperado para una MAP a una altura de 1 m.

Posterior a la ejecución de dichos 3 pasos para cada imagen del grupo de 136 imágenes, su resultado se inspeccionó visualmente verificando que la región demarcada como mina corresponda en buena parte a la región real con presencia de mina, es decir, pueden faltar o sobrar píxeles en la región definida como mina; esta imprecisión no es muy importante para la persona encargada de desminar y debería tener precaución considerando un margen de seguridad. La Figura 4.1 presenta dos ejemplos de inspección de la zona 7 con una MAP enterrada a 5 cm, donde la imagen a la izquierda corresponde a un caso considerado exitoso mientras que la de la derecha no; ambos resultados se obtuvieron sobre la misma imagen pero usando clasificadores diferentes; por lo que en 4.1a el clasificador MLP acierta en la localización de la MAP, mientras que en 4.1b el clasificador Naive Bayes demarca un área errada (falso positivo), lo que en la mayoría de los casos ocurre por presencia de piedras en el suelo; no obstante, en el marco de este trabajo, los falsos positivos tienen un costo mucho inferior a un falso negativo.




Figura 4. 1. Demarcación del área de MAP por parte de los clasificadores: a) Demarcación acertada de la MAP clasificador MLP; b) Demarcación errada de la MAP clasificador Naive Bayes.

La Tabla 4.13 presenta los resultados de la comparación visual en la localización de las minas para cada uno de los cinco clasificadores (MLP, SVM, Naive Bayes, RBF y KNN), sombreando con un azul más oscuro los mejores resultados en cada fila (criterio de análisis). La tabla utiliza cuatros criterios de agrupamiento para el análisis que se encuentran demarcados con bordes gruesos: 1) usando el conjunto total de imágenes, 2) por fecha de adquisición de las imágenes, 3) de acuerdo con la profundidad a la que está enterrada la mina, y 4) considerando tanto la fecha de captura como la profundidad de la mina; este último resulta ser más específico para evaluar la detección según las variables de profundidad y condiciones climáticas.

			Cantidad de imágenes donde se acertó la demarcación de MAP en porcentaje según clasificador				
		Total de imágenes termográficas con MAP	MLP	SVM	Naive Bayes	RBF	KNN
Por el total de imágenes		136	97,1%	97,8%	85,3%	96,3%	91,2%
Por fecha de adquisición	Febrero 13, 2020	32	96,9%	96,9%	96,9%	96,9%	93,8%
	Febrero 24, 2020	40	95,0%	100,0%	75,0%	95,0%	80,0%
	Marzo 3, 2020	64	98,4%	96,9%	85,9%	96,9%	96,9%
Por profundidad de la MAP	1 cm	68	97,1%	100,0%	86,8%	98,5%	88,2%
	5 cm	44	97,7%	95,5%	79,5%	93,2%	95,5%
	10 cm	24	95,8%	95,8%	91,7%	95,8%	91,7%
Por fecha de adquisición y profundidad respectivamente	Febrero 13, 2020	1 cm	9	100,0%	100,0%	100,0%	100,0%
		5 cm	12	100,0%	100,0%	100,0%	100,0%
		10 cm	11	90,9%	90,9%	90,9%	81,8%
	Febrero 24, 2020	1 cm	26	92,3%	100,0%	65,4%	96,2%
		5 cm	11	100,0%	100,0%	90,9%	100,0%
		10 cm	3	100,0%	100,0%	66,7%	66,7%
	Marzo 3, 2020	1 cm	33	100,0%	100,0%	100,0%	100,0%
		5 cm	21	95,2%	90,5%	57,1%	90,5%
		10 cm	10	100,0%	100,0%	90,0%	100,0%

Tabla 4. 13. Resultados de clasificación en la detección de MAP por diferentes criterios de agrupamiento para imágenes sin contrastar.

De tabla 4.13 puede concluirse que en general, entre todos los clasificadores, con SVMs se obtienen los mejores resultados con casi todos los criterios de agrupamiento, seguido de las redes neuronales tipo MLP; es interesante notar que en la mayoría de los casos con ambos clasificadores se obtienen los mejores resultados, y cuando no es así, uno de ellos presenta el mejor desempeño. Por lo anterior, cuando se analiza considerando el total de imágenes, con SVMs se alcanza un acierto en la demarcación de MAP del 97,8% y del 97,1% con el clasificador MLP.

Si se tiene en cuenta la fecha de adquisición, los mejores resultados se lograron para las imágenes del 13 de Febrero de 2020 donde se presentaron 10 días previos secos a la captura, obteniéndose un 96,9% de acierto con cualquier clasificador exceptuando KNN. En las imágenes capturadas el 24 de Febrero de 2020, el suelo tenía mayor humedad pues se había presentado lluvias 4 días consecutivos anteriores a la captura, por lo que solo con SVM se logró un 100% en la demarcación

de las minas. Finalmente, con las imágenes adquiridas el 3 de Marzo de 2020, donde hubo 4 días previos secos, se logró con 4 de los 5 clasificadores un desempeño igual o superior al logrado en las primeras capturas del 13 de Febrero; estas capturas tuvieron medidas similares en cuanto a la humedad en el aire y la radiación, pero los resultados indican que es más fácil identificar las MAPs cuando el suelo está menos seco. En otras palabras, aunque no se midió la humedad del suelo, esta parece incidir de forma positiva en la detección.

Si se considera la profundidad, como era de esperarse los resultados mejoran cuando las minas están enterradas a menor profundidad, lográndose un máximo del 100% con SVMs cuando la profundidad es de 1 cm, 97,7% con MLPs cuando están a 5 cm, y de 95,8% cuando están a 10 cm con tres clasificadores (MLP, SVM y RBF).

Considerando tanto la fecha de adquisición como la profundidad a las que fueron enterradas las minas, se confirma que cuando se encuentran a 1 cm de profundidad se puede lograr un 100% en la detección con casi todos los clasificadores, pero fueron más difíciles de detectar las adquiridas el 24 de Febrero, cuando aparentemente había más humedad en el suelo, no obstante, en este caso particular también se logró un reconocimiento del 100% usando SVMs. Cuando la profundidad fue de 5 cm se logró un 100% con casi todos los clasificadores, menos para las capturas del 3 de Marzo donde se logró como máximo una detección del 95,2%. Finalmente, si las minas están enterradas a 10 cm de profundidad se logró una demarcación del 100% con al menos 3 clasificadores, menos para las capturas del 13 de Febrero (90,2%); donde el suelo aparentemente estaba más seco. En todos los casos, y como se esperaba, las MAPs fueron difíciles de reconocer con mayores condiciones de humedad en el suelo. Las minas más superficiales (1 cm) fueron las más fáciles de reconocer siempre que la humedad en el suelo no sea alta. La ubicación de las minas a 5 cm se favoreció del suelo seco; mientras que las minas a 10 cm se vieron favorecidas por la humedad no excesiva del suelo.

A continuación se presentarán imágenes termográficas de ejemplo con la demarcación resultante para cada uno de los cinco clasificadores, y ordenándolos según la fecha de adquisición y diferenciándolas por zona de inspección.

4.2.1 Resultados de detección de MAP en imágenes termográficas adquiridas en Febrero 13, 2020

Los resultados de segmentación de MAP en imágenes termográficas por zona de inspección y clasificador para la adquisición realizada en Febrero 13, 2020, se exponen en la Tabla 4.14.



















Clasificador	Profundidad					
	1 cm			5 cm		10 cm
	Zona 1	Zona 2	Zona 3	Zona 7	Zona 8	Zona 9
MLP						
SVM						
Naive Bayes						
RBF						
KNN						

Tabla 4. 14. Resultados de segmentación de la MAP por zona de inspección y clasificador para la fecha Febrero 13, 2020.

Todas las imágenes de ejemplo presentadas en la Tabla 4.14 se consideran casos exitosos en la demarcación de las MAPs, y gracias a la consideración del área mínima teórica de una MAP, se logra que permanezca sólo una región demarcada, rechazando falsos positivos ante la presencia de rocas. Por otro lado, el resultado del área demarcada como MAP es similar para todos los clasificadores y presenta irregularidades en su forma a causa de la dispersión de la firma térmica, y en ese sentido, son más uniformes los logrados con el clasificador de Naive Bayes seguidos por lo de la MLP, mientras que las respuestas más irregulares ocurrieron con la SVM.

Otro aspecto interesante, es que parece haber una relación entre el área de la firma térmica de las MAPs y el contraste entre éstas y el suelo en las imágenes; así, cuando el contraste es mayor, la firma de la mina es más intensa (brillante) pero su área asociada es menor.

Finalmente, otro aspecto que llama la atención es que las minas más profundas en las imágenes térmicas presentan una mayor área en su firma térmica. Lo anterior puede estar relacionado con que el almacenamiento de energía térmica cuando la MAP se encuentre a una mayor profundidad y, en particular, cuando el suelo no es excesivamente húmedo afectando el calor específico del suelo, bajo estas condiciones el calentamiento es más lento y prevalece más en el tiempo [90]. Por otro lado, la humedad disminuye la resistividad térmica[91].

4.2.2 Resultados de detección de MAP en imágenes termográficas adquiridas en Febrero 24, 2020

Los resultados de segmentación de MAP en imágenes termográficas por zona de inspección y clasificador para la adquisición realizada en Febrero 24, 2020, se exponen en Tabla 4.15































Clasificador	Profundidad					
	1 cm			5 cm		10 cm
	Zona 1	Zona 2	Zona 3	Zona 7	Zona 8	Zona 9
MLP						
SVM						
Naive Bayes						
RBF						
KNN						

Tabla 4. 15. Resultados de segmentación de la MAP por zona de inspección y clasificador para la fecha Febrero 24, 2020.

Para esta fecha se presentaron 4 días consecutivos de lluvia previos a la captura, y como resultado se aprecia un menor contraste en todas las imágenes frente a las de la Tabla 4.15, lo cual redunda en la correcta identificación de las MAPs, por lo tanto, aquí sí se presentan casos no exitosos en la localización que se demarcan en un recuadro naranja, además, a través del círculo azul se indica la localización de la MAP. En el análisis de las imágenes de Febrero 13, se había concluido que entre menor era el contraste menor es el área brillante asociada a una MAP, dado que estas imágenes tienen menor contraste, esta área es mucho menor, lo que tiene como consecuencia que no se ubique la mina real con dos clasificadores (Naive Bayes y KNN).

En cuanto al área de la firma térmica, también es mayor para las minas más profundas, pero ahora se presentan muchas más irregularidades y se llega a detectar como mina una mayor parte del suelo.

4.2.3 Resultados de detección de MAP en imágenes termográficas adquiridas en Marzo 3, 2020

Los resultados de segmentación de MAP en imágenes termográficas por zona de inspección y clasificador para la adquisición realizada en Marzo 3, 2020, se exponen en la Tabla 4.16.












Clasificador	Profundidad					
	1 cm			5 cm		10 cm
	Zona 1	Zona 2	Zona 3	Zona 7	Zona 8	Zona 9
MLP						
SVM						
Naive Bayes						
RBF						
KNN						

Tabla 4. 16. Resultados de segmentación de la MAP por zona de inspección y clasificador para la fecha Febrero 24, 2020.

Para esta fecha se presentaron 4 días consecutivos de tiempo seco previos a la captura, y como resultado se apreciaba un contraste un poco menor en todas las imágenes frente a las de la Tabla 4.14 pero mayor a las de la Tabla 4.15, así mismo, se observan un mayor número de píxeles con valores brillantes sobre las MAPs. En consecuencia, se corrobora que el área de las MAPs detectadas son mayores a las de la Tabla 4.15 y menores que las de la Tabla 4.14.

Previamente se había identificado que las condiciones de captura para esta fecha favorecieron la identificación de las minas enterradas a 10 cm, donde visualmente

se puede apreciar una mejora del contraste respecto a las fechas anteriores, mejorando su detectabilidad y haciendo más regular la forma de la región establecida como MAP. Por el contrario, las minas enterradas a 5 cm se favorecerían con el suelo más seco, por lo que bajo las condiciones de captura de esta fecha (Marzo 3) las minas tienen un contraste menor frente a las de la Febrero 13, lo que a su vez incide en su reconocimiento.

4.3 RESULTADOS EXPLORATORIOS DE CLASIFICACIÓN USANDO LA TÉCNICA DE VENTANA DESLIZANTE SOBRE EL TOTAL DE IMÁGENES TERMOGRÁFICAS AÉREAS DEL SUELO SIN CONTRASTAR CAPTURADAS A ALTURAS ENTRE 2 Y 5 M

Aunque el objetivo del presente trabajo se centra en el análisis de imágenes adquiridas a 1 m de altura, se evaluó la demarcación de las minas aumentando la altura desde 2 a 5 m. A estas alturas sin embargo, había un número menor de imágenes, por lo que sólo se constituyen en resultados preliminares. Cuando se evalúa la clasificación y la demarcación a alturas diferentes de 1 m, cambia el tamaño de las ventanas deslizantes así como su desplazamiento y ROIs a extraer (ver tabla 4.17), por lo tanto, las ROIs sobre las que se calculan las características son más pequeñas en la medida que la altura aumenta, pero por lo demás se usan las mismas arquitecturas de los clasificadores para imágenes sin contrastar usadas anteriormente.

<i>Conjunto de Imágenes termográficas por altura</i>	<i>Dimensión de la ROI (píxeles)</i>	<i>Desplazamiento vertical y horizontal por ROI extraída en clasificación (píxeles)</i>	<i>Cantidad de ROIs extraídas en clasificación por imagen</i>
Conjunto 2m	8 x 8	2	20625
Conjunto 3m	5 x 5	2	20916
Conjunto 4m	4 x 4	1	84249
Conjunto 5m	3 x 3	1	84836

Tabla 4. 17. Definición de parámetros utilizados para cada conjunto de imágenes según la altura de adquisición para la etapa de clasificación con ventana deslizante.

Dado que previamente se encontró que las condiciones de captura de Febrero 24 en donde hay mayor humedad del suelo no favorecen la ubicación de MAPs, por lo que para este ejercicio se consideran solo las capturas de Febrero 13 y Marzo 3. Sin embargo, si se consideran los resultados previos sólo en estas dos fechas, las MLPs logran un mejor desempeño que las SVMs, ya que las MLPs pasan de un

desempeño de 97,1% considerando las tres capturas a 97.9% para las dos capturas; mientras que las SVMs pasan de 97,8% para las tres capturas a 96.9% para las dos capturas.

Por lo anterior, para la presentación de estos resultados se entrenan redes neuronales tipo MLP conservando la arquitectura utilizada en los resultados previos, y para ello, se construyó una base de datos para entrenar la MLP y posteriormente evaluar sus resultados, repitiendo este proceso para cada una de las 4 alturas (2, 3, 4 y 5 m).

Las bases de datos por altura se crearon a partir de 12 imágenes de las que se extrajeron 96 ROIs, balanceando los ejemplos de minas y suelo. De estas 96 ROIs, se usaron 72 (75%) durante el entrenamiento de las MLPs, y las 24 ROIs restantes para prueba (25%). La Tabla 4.18 presenta los resultados alcanzados por las diferentes redes MLP para cada una de las alturas a las que fueron entrenadas, sólo para los datos de prueba y usando las métricas de exactitud y de sensibilidad.

<i>Conjunto de Imágenes termográficas por altura</i>	Resultados para datos de prueba del clasificador MLP	
	<i>Exactitud (%)</i>	<i>Sensibilidad (%)</i>
Conjunto 2 m	94,4	94,4
Conjunto 3 m	100	100
Conjunto 4 m	97,2	100
Conjunto 5 m	100	100

Tabla 4. 18. Resultados para los datos de prueba del clasificador MLP por conjunto de imágenes según altura.

Los resultados de la Tabla 4.18 indican que el sistema podría ser extendido al uso de imágenes capturadas a alturas mayores a 1 m, para la que fue construido, lográndose porcentajes altos de sensibilidad y exactitud. Sin embargo, no parece haber una relación clara entre el aumento de la altura con los valores de las métricas de desempeño, sino que pareciese las máquinas de aprendizaje dado el bajo número de datos de entrenamiento, está siendo sensibles a la elección de los datos usados para entrenamiento y validación; por lo que es conveniente realizar un estudio más amplio antes de lanzar una conclusión asociada a la altura.

En la Tabla 4.19 se exponen los resultados del clasificador MLP discriminando los resultados por la altura a la que fueron adquiridas las imágenes. En todos los casos,

corresponden al uso de la técnica de ventana deslizante. En la Tabla aparecen sombreados con un azul más oscuro los mejores resultados en cada fila (criterio de análisis) y utiliza cuatros criterios de agrupamiento para el análisis que se encuentran demarcados con bordes gruesos: 1) usando el conjunto total de imágenes, 2) por fecha de adquisición de las imágenes, 3) de acuerdo con la profundidad a la que está enterrada la mina, y 4) considerando tanto la fecha de captura como la profundidad de la mina.

				Cantidad de imágenes donde se acertó la demarcación de MAP en porcentaje según altura			
			Total de imágenes termográficas con MAP	2 m	3 m	4 m	5 m
Por el total de imágenes			12	100,0%	91,7%	91,7%	33,3%
Por fecha de adquisición	Febrero 13, 2020		6	100,0%	83,3%	83,3%	33,3%
	Marzo 3, 2020		6	100,0%	100,0%	100,0%	33,3%
Por profundidad de la MAP	1 cm		6	100,0%	100,0%	100,0%	16,7%
	5 cm		4	100,0%	75,0%	83,3%	25,0%
	10 cm		2	100,0%	100,0%	100,0%	100,0%
Por fecha de adquisición y profundidad respectivamente	Febrero 13, 2020	1 cm	3	100,0%	100,0%	100,0%	33,0%
		5 cm	2	100,0%	50,0%	50,0%	0,0%
		10 cm	1	100,0%	100,0%	100,0%	100,0%
	Marzo 3, 2020	1 cm	3	100,0%	100,0%	100,0%	0,0%
		5 cm	2	100,0%	100,0%	100,0%	50,0%
		10 cm	1	100,0%	100,0%	100,0%	100,0%

Tabla 4. 19. Resultados de clasificación en la detección de MAP para imágenes sin contrastar para el clasificador MLP por altura.

De la Tabla 4.19 se puede evidenciar que las condiciones de captura de Marzo 3 contribuyeron a una mejor localización de las MAPs. Por otro lado, las minas más superficiales fueron ubicadas correctamente para alturas de hasta 4 metros. En el caso de las minas a 5 cm de profundidad, cuando se aumenta la altura, ya no se obtienen buenos resultados con las capturas del suelo seco (Febrero 13), sino que su ubicación mejora con un suelo menos seco (Marzo 3). Por otro lado, curiosamente cuando se aumentó la altura de captura de las minas a 10 cm de profundidad mejoró su localización lo cual puede estar asociado a que éstas presentan un área mayor de firma térmica.

5 CONCLUSIONES

Se logró desarrollar un sistema de detección de MAPs tipo quiebrapatas inspeccionando imágenes termográficas aéreas de un suelo natural a partir de la implementación y evaluación de cinco máquinas de aprendizaje diferentes.

Para lograr una experimentación segura se construyeron 8 minas antipersonales artesanales, con elementos de fácil consecución, y con características externas e internas bastante cercanas a las reales. La principal diferencia fue el uso de carbón de antracita en lugar de TNT.

Las minas fueron enterradas en un terreno de 10 metros cuadrados a profundidades entre 1 y 10 cm de la superficie, para posteriormente adquirir imágenes a una altura de 1 m, mediante la cámara termográfica FLIR Zenmuse XT montada sobre un dron MATRICE 100; condiciones bajo las cuales se realizaron tres sobrevuelos en días diferentes y siguiendo un protocolo propuesto para conformar un banco de imágenes termográficas aéreas. Los días elegidos para las capturas permitieron evaluar el sistema bajo condiciones diferentes de humedad relativa del aire, radiación solar y humedad del suelo.

Se evaluó el uso de la técnica de mejoramiento de contraste térmico CTFF, encontrando que bajo los parámetros usados no contribuyó significativamente en la ubicación de las minas, y el sistema podía prescindir de este tiempo de procesamiento sin deteriorar el desempeño del sistema para la ubicación de MAPs.

Se amplió el número y tipo de características que pueden ser usadas para la detección de minas, para después establecer cuáles de ellas eran las más discriminantes, concluyendo que las mejores son los valores de intensidad máximo y mínimo, el valor de intensidad medio, y la energía a 90° como medida de la textura. Los tres primeros coincidieron con los usados en [82]

Estas características se extrajeron de pequeñas partes de las imágenes (ventanas deslizantes de tamaño 16x16), y se entrenaron 5 máquinas de aprendizaje para que distinguieran entre mina y suelo; estas máquinas fueron: Redes Neuronales Artificiales tipo MLP, Máquinas de Vectores de Soporte (SVM), clasificadores Naive Bayes, Redes Neuronales Artificiales tipo RBF y clasificadores k-Vecinos más cercanos.

Para mejorar la identificación de las minas provistas por los clasificadores, se propuso una metodología de reconocimiento automático en donde se consideraba la clasificación de 3 ventanas autodeslizantes vecinas, y se minimizaron los falsos positivos usando el criterio de área teórica de la mina. Los resultados indicaron que el mejor porcentaje global se lograba con SVM (97,8%) seguida por la MLP (97,1%), si se consideran todas las imágenes adquiridas. Si se descartan las imágenes de Febrero 24, en donde llovió 4 días consecutivos previos a la captura, las MLP tienen un mejor desempeño (97,9%) frente a SVM (96.9%).

La humedad del suelo influyó en la detección de MAPs, para la primer fecha de captura (Febrero 13) donde existieron 10 días consecutivos sin lluvia, las minas más superficiales (1 cm y 5 cm) fueron las que se llevaron los mejores resultados de detección, además el contraste de estos artefactos en estas imágenes IR fue superior, llegando a presentar una firma térmica brillante aunque con un área asociada no tan mayor; en la segunda captura (Febrero 24), la humedad en el suelo fue alta, en esta existieron 4 días consecutivos previos con lloviznas, el contraste en las imágenes fue pobre y el área relacionada a la MAP baja, lo que causó errores en su localización, y la tercer fecha (Marzo 3) en el que se reportó 4 días consecutivos previos sin lluvias, es decir, un suelo menos seco comparado al de la primer captura, el contraste fue un poco menor, pero el área de la MAP en la imagen algo mayor, lo cual favoreció a la detección de las MAPs más profundas (10 cm).

Se constata que los resultados a las alturas de 2 a 5 m son inferiores respecto a las de 1 m, demostrando que a una mayor altura de adquisición el área de la firma térmica de la MAP se hace más pequeña lo que dificulta su detección, además, la cantidad de imágenes disponibles dificultó tener una base de datos de entrenamiento más grande, lo cual hace que el clasificador no tenga un gran poder de generalización, sin embargo, se evidenció que a contraposición de los resultados a 1 m, para estas imágenes se acierta en todos los casos la zona con la MAP a 10 cm, por lo que su profundidad favorece en la dispersión térmica sobre el área circundante de la MAP sobre el suelo.

De las pruebas y los análisis anteriormente realizados se reafirma, principalmente, que la mejor franja horaria para las pruebas termográficas, dada la ubicación geográfica y en función de la practicidad del procedimiento y de la maximización del contraste térmico, es entre 5:00 y 6:00 pm; que la humedad almacenada en exceso en el suelo constituye una condición que, si bien en principio entorpece la inspección termográfica, puede compensarse con la combinación de técnicas de

reconocimiento de patrones y procesamiento digital de imágenes, con el fin de mantener la detectabilidad de las MAP, sobre todo para las minas más superficiales; que la morfología y la propia construcción de las MAP artesanales constituyen una información que puede ser útil para la detección automática de estos artefactos.

5.1 PRODUCTOS DEL TRABAJO DE INVESTIGACIÓN

A partir del trabajo de investigación desarrollado, se obtuvieron los siguientes productos:

- Artículo publicado en la revista engineering proceedings.
- Artículo publicado en la revista Infrared Physics and Technology.
- Artículo sometido en la revista Data in Brief.
- Artículo borrador para someter en la revista Applied Optics.
- Ponencia en el AITA 2021.

En Anexos se incluye el enlace al repositorio donde se encuentra la evidencia de los productos descritos.

5.2 TRABAJOS FUTUROS

A continuación, se relacionan algunos aspectos que podrían contribuir a mejorar la detección de MAPs enterradas:

- Dado que los resultados en la detección de las minas mostraron ser sensibles a la humedad del suelo, es conveniente adicionar esta variable de experimentación para complementar las condiciones ambientales ya establecidas.
- Dado que los resultados evidenciaron que los mejores clasificadores para la detección de minas fueron SVM y MLP, se puede construir una metodología que considere la clasificación de ambos, en lugar de usarlos por separado.
- Exploración de técnicas de reconocimiento basadas en aprendizaje profundo para la detección de MAPs sobre imágenes termográficas.
- Aplicación de técnicas especializadas de segmentación con el propósito de presentar una demarcación de la MAP más precisa en las imágenes termográficas.
- Uso de multi-imágenes espectrales como información base, para mejorar aún más la robustez del sistema con respecto a condiciones ambientales no controladas.

- Incluir un análisis en el tiempo de la evolución térmica del suelo mediante algún mecanismo que acelere la difusión del calor en él.
- Determinar una medida de contraste térmico promedio en imágenes con presencia de MAP que favorezca el contraste de la MAP con respecto al fondo y que esto permita automatizar el procedimiento de selección de imágenes con el mejor contraste.
- Considerar en el modelo matemático propuesto para el cálculo de área teórico de una MAP en las imágenes según la altura de adquisición, la incertidumbre de la cámara termográfica utilizada para la captura.

REFERENCIAS

- [1] “International campaign to ban Landmines.” <http://www.icbl.org/en-gb/home.aspx> (accessed Oct. 30, 2022).
- [2] “La guerra escondida: Minas antipersonal y remanentes explosivos en Colombia.” http://www.centrodememoriahistorica.gov.co/descargas/informes-accesibles/la-guerra-escondida_accesible.pdf (accessed Oct. 30, 2022).
- [3] Gobierno de Colombia, “Víctimas de Minas Antipersonal y Municiones sin Explosionar,” 2019. <http://www.accioncontraminas.gov.co/estadisticas/Paginas/victimas-minas-antipersonal.aspx> (accessed Jun. 04, 2021).
- [4] “Scopus.” <https://www-scopus-com.bd.univalle.edu.co/term/analyzer.uri?sid=268013a570c1d44e6d95023febcb29c0e&origin=resultslist&src=s&s=TITLE-ABS-KEY%28landmine+detection%29&sort=plf-f&sdt=b&sot=b&sl=33&count=2303&analyzeResults=Analyze+results&txGid=36a37dfade80ddbd>
- [5] S. Gutierrez *et al.*, “Advances on the detection of Landmines and IEDs in Colombia using UWB GPR and Machine Learning Techniques,” in *15th European Conference on Antennas and Propagation, EuCAP 2021*, Mar. 2021. doi: 10.23919/EuCAP51087.2021.9411214.
- [6] B. Pongrac, A. Sarjas, and D. Gleich, “Advanced Techniques for Landmine Detection using UAV,” in *International Conference on Systems, Signals, and Image Processing*, 2022, vol. 2022-June. doi: 10.1109/IWSSIP55020.2022.9854497.
- [7] H. Frigui, P. Gader, and J. Keller, “Fuzzy clustering for land mine detection,” *Annual Conference of the North American Fuzzy Information Processing Society - NAFIPS*, pp. 261–265, 1998, doi: 10.1109/NAFIPS.1998.715577.
- [8] H. Frigui, O. Missaoui, and P. Gader, “Landmine detection with ground penetrating radar using discrete hidden Markov models with symbol dependent features,” *Detection and Sensing of Mines, Explosive Objects, and Obscured Targets XIII*, vol. 6953, no. 6, p. 69531C, 2008, doi: 10.1117/12.782420.
- [9] K. Tbarki, S. Ben Said, R. Ksantini, and Z. Lachiri, “RBF kernel based SVM classification for landmine detection and discrimination,” *IPAS 2016 - 2nd*

- International Image Processing, Applications and Systems Conference*, pp. 1–6, 2017, doi: 10.1109/IPAS.2016.7880146.
- [10] X. Song, D. Xiang, K. Zhou, and Y. Su, “Improving RPCA-based clutter suppression in GPR detection of antipersonnel mines,” *IEEE Geoscience and Remote Sensing Letters*, vol. 14, no. 8, pp. 1338–1342, 2017, doi: 10.1109/LGRS.2017.2711251.
 - [11] N. V. Nambiar, K. Gurpreet, and A. Shobha, “Automatic Landmine Detection by Pattern Trace,” *2017 International Conference on Computing, Communication, Control and Automation, ICCUBEA 2017*, pp. 1–5, 2018, doi: 10.1109/ICCUBEA.2017.8463717.
 - [12] H. Brunzell, “Detection of shallowly buried objects using impulse radar,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 37, no. 2 II, pp. 875–886, 1999, doi: 10.1109/36.752207.
 - [13] C. Fischer and W. Wiesbeck, “Multistatic GPR for antipersonnel mine detection,” *IGARSS 2001. Scanning the Present and Resolving the Future. Proceedings. IEEE 2001 International Geoscience and Remote Sensing Symposium (Cat. No.01CH37217)*, vol. 6, no. C, pp. 2721–2723, 2002, doi: 10.1109/igarss.2001.978141.
 - [14] C. Fischer, A. Herschlein, M. Younis, and W. Wiesbeck, “Detection of antipersonnel mines by using the factorization method on multistatic ground-penetrating radar measurements,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 45, no. 1, pp. 85–92, 2007, doi: 10.1109/TGRS.2006.883464.
 - [15] A. Goad *et al.*, “Landmine detection utilizing an unmanned aerial vehicle,” *Proceedings of the 2008 IEEE Systems and Information Engineering Design Symposium, SIEDS 2008*, pp. 231–236, 2008, doi: 10.1109/SIEDS.2008.4559717.
 - [16] I. J. Gupta and A. van der Merwe, “A novel signal processing technique for clutter reduction in GPR measurements of small, shallow land mines,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 38, no. 6, pp. 2627–2637, 2000, doi: 10.1109/36.885209.
 - [17] L. Collins, P. Gao, and L. Carin, “An improved bayesian decision theoretic approach for land mine detection,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 37, no. 2 I, pp. 811–819, 1999, doi: 10.1109/36.752197.
 - [18] C. A. Casas-Díaz and E. E. Roa-Guerrero, “Development of mobile robotics platform for identification of land mines antipersonal in different areas of Colombia,” *2015 IEEE Colombian Conference on Communications and*

- Computing, COLCOM 2015 - Conference Proceedings*, pp. 1–6, 2015, doi: 10.1109/ColComCon.2015.7152106.
- [19] M. Zubair and M. A. Choudhry, “Land mine detecting robot capable of path planning,” *WSEAS Transactions on Systems and Control*, vol. 6, no. 4, pp. 105–114, 2011, doi: 10.1109/WCSE.2010.34.
 - [20] L.-A. Garcia-Gutierrez, “Diseño y Construcción de un Sistema Robótico para la exploración de campos sembrados con Minas Antipersona,” 2008.
 - [21] I. Makki, R. Younes, C. Francis, T. Bianchi, and M. Zucchetti, “Classification algorithms for landmine detection using hyperspectral imaging,” *2017 1st International Conference on Landmine: Detection, Clearance and Legislations, LDCL 2017*, pp. 1–6, 2017, doi: 10.1109/LDCL.2017.7976930.
 - [22] G. A. Clark, S. K. Sengupta, W. D. Aimonetti, F. Roeske, and J. G. Donetti, “Multispectral Image Feature Selection for Land Mine Detection,” vol. 38, no. 1, pp. 304–311, 2000.
 - [23] X. Miao, M. R. Azimi-Sadjadi, B. Tian, A. C. Dubey, and N. H. Witherspoon, “Detection of mines and minelike targets using principal component and neural-Network methods,” *IEEE Trans Neural Netw*, vol. 9, no. 3, pp. 454–463, 1998, doi: 10.1109/72.668887.
 - [24] A. Filippidis, L. C. Jain, and N. M. Martin, “Using genetic algorithms and neural networks for surface land mine detection,” *IEEE Transactions on Signal Processing*, vol. 47, no. 1, pp. 176–186, 1999, doi: 10.1109/78.738250.
 - [25] L. Cardona, J. Jiménez, and N. Vanegas, “Resonancia nuclear en cuadrupolo para la detección de explosivos,” *Ingeniare*, vol. 23, no. 3, pp. 458–472, 2015, doi: 10.4067/S0718-33052015000300015.
 - [26] G. J. Lockwood, “Field tests of X-ray backscatter mine detection,” pp. 160–163, 2005, doi: 10.1049/cp:19980711.
 - [27] D. G. Beetner, R. J. Stanley, S. Agarwal, D. R. Somasundaram, K. Nema, and B. Mantha, “Landmine detection and discrimination using high-pressure waterjets,” *EURASIP J Appl Signal Processing*, vol. 2004, no. 13, pp. 1973–1984, 2004, doi: 10.1155/S1110865704406040.
 - [28] H. F. M. Ali, A. M. R. Fath El-Bab, Z. Zyada, and S. M. Megahed, “Estimation of landmine characteristics in sandy desert using neural networks,” *Neural Comput Appl*, vol. 28, no. 7, pp. 1801–1815, 2017, doi: 10.1007/s00521-015-2153-z.
 - [29] K. Wasaki, N. Shimoj, Y. Takita, and P. N. Kawamoto, “A smart sensing method for mine detection using time difference IR images,” pp. 133–139, 2002, doi: 10.1109/mfi.2001.1013521.

- [30] K. M. Mahar, M. S. Ibrahim, and M. Z. Riad, "Landmines recognition system using thermovision techniques," *Proceedings - International Conference on Image Processing, ICIP*, pp. 585–588, 2009, doi: 10.1109/ICIP.2009.5413883.
- [31] B. Szymanik and S. Gratkowski, "Numerical and experimental validation of optimization results in microwave enhanced infrared landmines' detection," *IEEE Trans Magn*, vol. 51, no. 3, pp. 18–21, 2015, doi: 10.1109/TMAG.2014.2356338.
- [32] G. A. Clark *et al.*, "Detecting buried objects by fusing dual-band infrared images," pp. 135–143, 2002, doi: 10.1109/acssc.1993.342486.
- [33] Y. Ganesh, R. Raju, and R. Hegde, "Surveillance Drone for Landmine Detection," *Proceedings - 2015 21st Annual International Conference on Advanced Computing and Communications, ADCOM 2015*, pp. 33–38, 2016, doi: 10.1109/ADCOM.2015.13.
- [34] P. Krause, E. Salahat, and E. Franklin, "Diurnal thermal dormant landmine detection using unmanned aerial vehicles," *Proceedings: IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society*, vol. 1, pp. 2299–2304, 2018, doi: 10.1109/IECON.2018.8591378.
- [35] K. Lamorski, P. Pręgowski, W. Swiderski, D. Szabra, R. T. Walczak, and B. Usowicz, "Thermal signatures of land mines buried in mineral and organic soils - Modelling and experiments," *Infrared Phys Technol*, vol. 43, no. 3–5, pp. 303–309, 2002, doi: 10.1016/S1350-4495(02)00156-1.
- [36] A. Muscio and M. A. Corticelli, "Land mine detection by infrared thermography: Reduction of size and duration of the experiments," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 42, no. 9, pp. 1955–1964, 2004, doi: 10.1109/TGRS.2004.831443.
- [37] J. S. Silva, I. F. L. Guerra, J. Bioucas-Dias, and T. Gasche, "Landmine Detection Using Multispectral Images," *IEEE Sens J*, vol. 19, no. 20, pp. 9341–9351, Oct. 2019, doi: 10.1109/JSEN.2019.2925203.
- [38] L. Cardona, H. Itozaki, J. Jiménez, N. Vanegas, and H. Sato-Akaba, "Spectral descriptors and supervised classifier for ammonium nitrate detection in landmines by nuclear quadrupole resonance," *Journal of Magnetic Resonance*, vol. 305, pp. 104–111, Aug. 2019, doi: 10.1016/j.jmr.2019.06.009.
- [39] "Steeped Frequency and UW B Pulse Based Radars for Landmine Detection."
- [40] A. Y. Sun *et al.*, "Method for accurate position detection of landmine based on PGNA technology," *J Radioanal Nucl Chem*, vol. 320, no. 2, pp. 323–328, May 2019, doi: 10.1007/s10967-019-06498-6.

- [41] H. F. M. Ali, A. M. R. F. el Bab, Z. Zyada, and S. M. Megahed, "Inclination angle effect on landmine characteristics estimation in sandy desert using neural networks," in *2015 10th Asian Control Conference: Emerging Control Techniques for a Sustainable World, ASCC 2015*, Sep. 2015. doi: 10.1109/ASCC.2015.7244615.
- [42] Han'guk T'ongsin Hakhoe, IEEE Communications Society, Denshi Jōhō Tsūshin Gakkai (Japan). Tsūshin Sosaieiti, and Institute of Electrical and Electronics Engineers, *ICTC 2017: International Conference on ICT Convergence 2017: "ICT Convergence Technologies Leading the Fourth Industrial Revolution": October 18-20, 2017, Lotte City Hotel Jeju, Jeju Island, Korea*.
- [43] A. Alzeyadi, J. Hu, and T. Yu, "Detecting underground metallic objects of different sizes using synthetic aperture radar," Mar. 2019, p. 107. doi: 10.1117/12.2514480.
- [44] W. Rafique, D. Zheng, J. Barras, S. Joglekar, and P. Kosmas, "Predictive Analysis of Landmine Risk," *IEEE Access*, vol. 7, pp. 107259–107269, 2019, doi: 10.1109/ACCESS.2019.2929677.
- [45] J. M. Malof et al., "A large-scale multi-institutional evaluation of advanced discrimination algorithms for buried threat detection in ground penetrating radar," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 57, no. 9, pp. 6929–6945, Sep. 2019, doi: 10.1109/TGRS.2019.2909665.
- [46] IEEE Robotics and Automation Society. Tunisia Chapter, IEEE-Tunisia Section, Institute of Electrical and Electronics Engineers. Region 8, and Institute of Electrical and Electronics Engineers, *2017 International Conference on Control, Automation and Diagnosis (ICCAD) : 19-21 Jan. 2017*.
- [47] G. Borgioli et al., "A Hologram Reconstruction Algorithm for Landmine Recognition and Classification Based on Microwave Holographic Radar Data," 2018.
- [48] Mass.) IEEE Antennas and Propagation Society. International Symposium (2018: Boston, Institute of Electrical and Electronics Engineers, IEEE Antennas and Propagation Society, and Mass.) USNC-URSI Radio Science Meeting (2018 : Boston, *2018 IEEE International Symposium on Antennas and Propagation : proceedings : 8-13 July 2018, the Westin Boston Waterfront, Boston, Massachusetts, USA*.
- [49] X. Shi, D. Cheng, Z. Song, and C. Wang, "A Real-time Method for Landmine Detection Using Vehicle Array GPR," in *2018 17th International Conference*

- on Ground Penetrating Radar, *GPR* 2018, Aug. 2018. doi: 10.1109/ICGPR.2018.8441584.
- [50] F. H. C. Tivive, A. Bouzerdoun, and C. Abeynayake, "GPR Target Detection by Joint Sparse and Low-Rank Matrix Decomposition," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 57, no. 5, pp. 2583–2595, May 2019, doi: 10.1109/TGRS.2018.2875102.
 - [51] M. Garcia-Fernandez, Y. Alvarez-Lopez, B. Gonzalez-Valdes, Y. Rodriguez-Vaqueiro, A. Arboleya-Arboleya, and F. las Heras, "Recent advances in high-resolution Ground Penetrating Radar on board an Unmanned Aerial Vehicle; Recent advances in high-resolution Ground Penetrating Radar on board an Unmanned Aerial Vehicle," 2019.
 - [52] E. Schreiber, A. Heinzl, M. Peichl, M. Engel, and W. Wiesbeck, "Advanced Buried Object Detection by Multichannel, UAV/Drone Carried Synthetic Aperture Radar," 2019.
 - [53] S. Kaya and U. M. Leloglu, "Buried and Surface Mine Detection from Thermal Image Time Series," *IEEE J Sel Top Appl Earth Obs Remote Sens*, vol. 10, no. 10, pp. 4544–4552, Oct. 2017, doi: 10.1109/JSTARS.2016.2639037.
 - [54] K. H. Ghazali and M. S. Jadin, "Detection improvised explosive device (IED) emplacement using infrared image," in *Proceedings - UKSim-AMSS 16th International Conference on Computer Modelling and Simulation, UKSim 2014*, 2014, pp. 307–310. doi: 10.1109/UKSim.2014.111.
 - [55] K. Hanton, M. Butavicius, R. Johnson, and J. Sunde, "Improving infrared images for standoff object detection," in *Proceedings of the International Conference on Information Technology Interfaces, ITI*, 2009, pp. 641–646. doi: 10.1109/ITI.2009.5196163.
 - [56] P. L. Martínez, L. van Kempen, H. Sahli, and D. C. Ferrer, "Improved thermal analysis of buried landmines," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 42, no. 9, pp. 1965–1975, Sep. 2004, doi: 10.1109/TGRS.2004.831884.
 - [57] F. Cremer, W. de Jong, and K. Schutte, "Processing of Polarimetric Infrared Images for Landmine Detection," 2003.
 - [58] A. Barnawi, N. Kumar, I. Budhiraja, K. Kumar, A. Almansour, and B. Alzahrani, "Deep reinforcement learning based trajectory optimization for magnetometer-mounted UAV to landmine detection," *Comput Commun*, vol. 195, pp. 441–450, Nov. 2022, doi: 10.1016/j.comcom.2022.09.002.
 - [59] M. García-Fernández, G. Álvarez-Narciandi, Y. Á. López, and F. L. H. Andrés, "Analysis and validation of a hybrid forward-looking down-looking ground

- penetrating radar architecture,” *Remote Sens (Basel)*, vol. 13, no. 6, Mar. 2021, doi: 10.3390/rs13061206.
- [60] L. S. Yoo, J. H. Lee, Y. K. Lee, S. K. Jung, and Y. Choi, “Application of a drone magnetometer system to military mine detection in the demilitarized zone,” *Sensors*, vol. 21, no. 9, May 2021, doi: 10.3390/s21093175.
 - [61] J. Baur, G. Steinberg, A. Nikulin, K. Chiu, and T. S. de Smet, “Applying deep learning to automate UAV-based detection of scatterable landmines,” *Remote Sens (Basel)*, vol. 12, no. 5, Mar. 2020, doi: 10.3390/rs12050859.
 - [62] M. García-Fernández, Y. Á. López, A. de Mitri, D. C. Martínez, G. Álvarez-Narciandi, and F. L. H. Andrés, “Portable and easily-deployable air-launched GPR scanner,” *Remote Sens (Basel)*, vol. 12, no. 11, Jun. 2020, doi: 10.3390/rs12111833.
 - [63] M. García-Fernández, Y. A. López, and F. Las-Heras Andrés, “Airborne multi-channel ground penetrating radar for improvised explosive devices and landmine detection,” *IEEE Access*, vol. 8, pp. 165927–165943, 2020, doi: 10.1109/ACCESS.2020.3022624.
 - [64] S. Dill, E. Schreiber, M. Engel, A. Heinzl, and M. Peichl, “A drone carried multichannel synthetic aperture radar for advanced buried object detection,” in *2019 IEEE Radar Conference, RadarConf 2019*, Apr. 2019. doi: 10.1109/RADAR.2019.8835814.
 - [65] R. Burr, M. Scharfel, P. Schmidt, W. Mayer, T. Walter, and C. Waldschmidt, “Design and Implementation of a FMCW GPR for UAV-based Mine Detection,” *2018 IEEE MTT-S International Conference on Microwaves for Intelligent Mobility, ICMIM 2018*, no. Icmim, pp. 1–4, 2018, doi: 10.1109/ICMIM.2018.8443526.
 - [66] M. G. Fernandez et al., “Synthetic aperture radar imaging system for landmine detection using a ground penetrating radar on board a unmanned aerial vehicle,” *IEEE Access*, vol. 6, pp. 45100–45112, Aug. 2018, doi: 10.1109/ACCESS.2018.2863572.
 - [67] J. Colorado et al., *Low-altitude autonomous drone navigation for landmine detection purposes*. 2017. doi: 10.0/Linux-x86_64.
 - [68] D. Šipoš, P. Planinšič, and D. Gleich, “On drone ground penetrating radar for landmine detection,” in *2017 1st International Conference on Landmine: Detection, Clearance and Legislations, LDCL 2017*, Jul. 2017, pp. 7–10. doi: 10.1109/LDCL.2017.7976931.
 - [69] J. Rodriguez, C. Castiblanco, I. Mondragon, and J. Colorado, “Low-cost quadrotor applied for visual detection of landmine-like objects,” in *2014*

International Conference on Unmanned Aircraft Systems, ICUAS 2014 - Conference Proceedings, 2014, pp. 83–88. doi: 10.1109/ICUAS.2014.6842242.

- [70] D. C. G. Rueda, “La Desegregación de las Minas Antipersonales, una guerra bajo tierra,” *Cell*, vol. 3, no. 4, pp. 1–15, 2014, doi: 10.1016/j.cell.2009.01.043.
- [71] El País de Cali, “Algunos tipos de Minas Antipersona.” <https://www.elpais.com.co/elpais/minas-antipersonales/graficos/grafico-descubra-algunos-tipos-minas-antipersonales>
- [72] N. Gama, D. Amaya, and O. Ramos, “Review of technologies for the detection of Anti-Personnel Plastic Mines,” 1385.
- [73] L. Cardona, J. Jiménez, and N. Vanegas, “Landmine Detection Technologies To Face the Demining Problem in Antioquia,” *Dyna (Medellin)*, vol. 81, no. 183, p. 115, 2014, doi: 10.15446/dyna.v81n183.37441.
- [74] “Un detector de minas antipersonas instalado en un Smartphone.” <https://www.colombia.com/tecnologia/visionarios/sdi/10764/un-detector-de-minas-antipersonas-instalado-en-un-smartphone>
- [75] “Estudios con Georadar - Radar de penetración terrestre - GPR.” <https://www.cartomex.com/georadar-gpr.html>
- [76] D. L. Balageas, “Termografía Infrarroja: una técnica multifacética para la Evaluación No Destructiva (END),” *IV conferencia Panamericana de END*, p. 14, 2007.
- [77] D. L. Balageas, “Termografía Infrarroja: una técnica multifacética para la Evaluación No Destructiva (END),” *IV conferencia Panamericana de END*, no. January 2007, p. 14, 2007.
- [78] D. Restrepo, “Contribución a la Solución del Problema de Detección y Caracterización de Defectos en Termografía Activa mediante Procesamiento Espacio-Temporal de Secuencias de Imágenes Infrarrojas,” p. 226, 2013.
- [79] G. Colmenares, “Inteligencia Artificial. Máquinas de vectores de soporte,” vol. IV, p. 11, 2011.
- [80] H.-D. Benitez-Restrepo, “Contribución a la Caracterización de Defectos en Termografía Infrarroja mediante Maquinas de Aprendizaje,” Universidad del Valle, Cali.
- [81] V. Riobó Otero, *Reconocimiento De Localizaciones Mediante Máquinas De Soporte Vectorial Autor: 2012*.
- [82] B. Garcia, “Detección de materiales de uso común en la estructura externa de Minas Antipersonal mediante la inspección Termográfica del suelo,” Universidad del Valle, Cali, 2016.

- [83] J. Cubides-Cárdenas, *Desafíos para la Seguridad y Defensa Nacional de Colombia: Teoría y Praxis*. 2017.
- [84] C. Yu, Z. Lin, and Y. Yu, "Principles and design of infrared gas concentration detection device," in *Proceedings - 2010 3rd International Conference on Biomedical Engineering and Informatics, BMEI 2010*, 2010, vol. 4, pp. 1556–1559. doi: 10.1109/BMEI.2010.5639263.
- [85] L. M. García-Moreno, J. P. Díaz-Paz, H. Loaiza-Correa, and A. D. Restrepo-Girón, "Dataset of thermal and visible aerial images for multi-modal and multi-spectral image registration and fusion," *Data Brief*, vol. 29, Apr. 2020, doi: 10.1016/j.dib.2020.105326.
- [86] J. Kyncl, L. Vetoschkin, L. Musalek, J. Bryscejn, and J. Sova, "The correction of the influence of wind on thermographic measurement," in *Proceedings - 2016 17th International Scientific Conference on Electric Power Engineering, EPE 2016*, Jul. 2016. doi: 10.1109/EPE.2016.7521772.
- [87] George Ginu, Mathew Rinoy, and Shelly Shani, "A Survey on Various Median Filtering Techniques For Removal of Impulse Noise From Digital Image," p. 287.
- [88] G. R. A. Kenneth E. Barner, "Order-statistic filtering and smoothing of time-series," 1998.
- [89] "Zenmuse XT FLIR User Manual," 2016. Accessed: Oct. 30, 2021. [Online]. Available: https://dl.djicdn.com/downloads/zenmuse_xt/en/Zenmuse_XT_User_Manual_V1.2_en_0708.pdf
- [90] T. Mejía-Bayas, "Segmentación y Análisis de Imágenes Termográficas mediante Descriptores de Textura Simples," Universidad Técnica de Ambato, Ambato.
- [91] A. Rojas, O. Zuñiga, M. Sanchez de Prager, J. Pérez, and J. M. Gascó, "Conductividad térmica del suelo, materia orgánica, actividad y biomasa microbianas en sistemas de cultivo de maracuyá en Toro, Valle del Cauca", Accessed: Dec. 10, 2022. [Online]. Available: <https://repository.agrosavia.co/handle/20.500.12324/19515>

ANEXOS

Anexo A. Caracterización del terreno de inspección para la detección de MAPs [82].

UNIVERSIDAD DEL VALLE
ESCUELA DE INGENIERIA CIVIL Y GEOMATICA
LABORATORIO DE SUELOS Y PAVIMENTOS



PROYECTO DETECCIÓN DE MATERIALES DE USO COMÚN EN LA ESTRUCTURA EXTERNA DE MINAS ANTIPERSONA MEDIANTE INSPECCIÓN TERMOCRÁFICA DEL SUELO

Fecha 28/01/2016
Fecha Muestreo 20/01/2016

SONDEO # NA

Muestra # 1

Profundidad (m)


ANÁLISIS GRANULOMÉTRICO DE SUELOS POR TAMIZADO
 I.N.V.I.E - 123


Peso Inicial (gr) 2863,1 **Peso lavado (gr)** 934,6

TAMIZ	Peso retenido gr	Porcentaje retenido %	Retenido acumulado %	Porcentaje pasa %
2"	0,0	0,0	0,0	100,0
1 1/2"	0,0	0,0	0,0	100,0
1"	0,0	0,0	0,0	100,0
3/4"	0,0	0,0	0,0	100,0
1/2"	175,6	6,1	6,1	93,9
3/8"	56,7	2,0	8,1	91,9
# 4	98,3	3,4	11,5	88,5
# 8	55,9	2,0	13,5	86,5
# 16	66,1	2,3	15,8	84,2
# 30	72,7	2,5	18,3	81,7
# 50	96,6	3,4	21,7	78,3
# 100	145,0	5,1	26,8	73,2
# 200	167,7	5,9	32,6	67,4
Pasa N°200	0,0	% gravas	48,4	
Total	934,6	% arenas	51,6	

LÍMITE LÍQUIDO Y PLÁSTICO DE LOS SUELOS
 I.N.V.I.E - 125 I.N.V.I.E - 126

# Golpes	LÍMITE LÍQUIDO			LÍMITE PLÁSTICO		Humedad Natural
	35	30	25			
P ₁ (gr)	33,88	41,58	44,96	27,14	27,97	
P ₂ (gr)	28,46	33,5	35,36	24,95	25,58	
P ₃ (gr)	17,05	17,30	16,76	17,89	17,84	
Humedad %	47,5	49,9	51,6	31,0	30,9	





Limite Líquido %	51,6
Limite Plástico %	30,9
Índice de Plasticidad %	20,7
Clasificación	M H

Diego Duque Arango
 Ingeniero Coordinador de Laboratorio

Carlos Alberto Manrique Londoño
 Ingeniero

Anexo B. Conjunto seleccionado para estudio: 136 Imágenes Termográficas capturadas del suelo a 1 metro de altura.

Anexo C. Productos resultantes a partir del desarrollo del trabajo de investigación.

NOTA: El Anexo B se encuentran en el siguiente enlace:
https://docs.google.com/spreadsheets/d/1rpUskaVXvvqAJA_Qn1VtBoPqsgffwXZS SOSjNQBxdw/edit?usp=share_link

NOTA: El Anexo C se encuentra en el siguiente enlace:
https://drive.google.com/drive/folders/11FXjXwCV_WbgaLG6eKGkr7mRRq5Kx_rs?usp=share_link