

# Identificación de asbesto-cemento en imágenes NIR mediante métodos de similitud espectral y redes neuronales artificiales

*Identification of asbestos-cement in NIR images via spectral similarity and artificial neural networks*

PhD. Gabriel Elías Chanchí Golondrino<sup>1</sup>,  
PhD. Manuel Alejandro Ospina Alarcón<sup>1</sup>, PhD. Manuel Saba<sup>2</sup>

<sup>1</sup> Universidad de Cartagena, Facultad de Ingeniería, Prog. de Ingeniería de Sistema, Cartagena, Bolívar, Colombia.

<sup>2</sup> Universidad de Cartagena, Facultad de Ingeniería, Prog. de Ingeniería Civil, Cartagena, Bolívar, Colombia.

Correspondencia: [gchanchig@unicartagena.edu.co](mailto:gchanchig@unicartagena.edu.co)

Recibido: 26 julio 2025. Aceptado: 20 diciembre 2025. Publicado: 01 enero 2026.

Cómo citar: G. E. Chanchí Golondrino, M. A. Ospina Alarcón y M. Saba, "Identificación de asbesto-cemento en imágenes NIR mediante métodos de similitud espectral y redes neuronales artificiales", RCTA, vol. 1, n.º. 47, pp. 46-61, ene. 2026.  
Recuperado de <https://ojs.unipamplona.edu.co/index.php/rcta/article/view/4108>

Esta obra está bajo una licencia internacional  
Creative Commons Atribución-NoComercial 4.0.



**Resumen:** Este estudio emplea imágenes multiespectrales aéreas obtenidas a partir del repositorio del Establecimiento Público Ambiental de Cartagena (EPA), las cuales cuentan con una resolución espacial de 0.17 m/píxel. El conjunto de datos está compuesto por cuatro bandas espectrales (R, G, B y NIR), a partir de las cuales se extrajeron 300 firmas espectrales de cubiertas de asbesto-cemento y 300 firmas de otros materiales. El etiquetado se realizó mediante interpretación visual apoyada en visitas de campo. Se evaluaron dos configuraciones del cubo de datos: una con las cuatro bandas multiespectrales y otra con cinco bandas, generada mediante la incorporación del primer componente principal obtenido mediante PCA. Se compararon tres medidas de similitud espectral (Cosine-Based Similarity (CBS), Spectral Distance Similarity (SDS) y Euclidean Distance Similarity (EDS)) junto con un modelo de red neuronal artificial (ANN). El desempeño se evaluó mediante división 70–30 utilizando métricas de precisión, recall, F1 y tiempo de ejecución. Los resultados indican que EDS y CBS alcanzaron la mayor exactitud en la detección, siendo EDS computacionalmente más eficiente (CBS fue 2,22 veces más lento). Estos hallazgos demuestran que EDS y CBS son métodos prometedores para la detección eficiente de cubiertas de asbesto-cemento a partir de imágenes multiespectrales, y pueden ser extrapolados a la identificación de otros materiales bajo condiciones similares de resolución espacial y calidad de datos.

**Palabras clave:** Asbesto-cemento, imágenes multiespectrales, similitud espectral, redes neuronales artificiales.

**Abstract:** This study employs airborne multispectral imagery obtained from the repository of the Environmental Public Agency of Cartagena (EPA), which provides a spatial resolution of 0.17 m/pixel. The dataset consists of four spectral bands (R, G, B, and NIR), from which 300 spectral signatures of asbestos-cement roofing and 300 signatures of other materials were extracted. The labeling was conducted through visual interpretation supported by field visits. Two configurations of the data cube were evaluated: one containing the four multispectral bands and another with five bands, generated by incorporating the first principal component obtained

through PCA. Three spectral similarity measures (Cosine-Based Similarity (CBS), Spectral Distance Similarity (SDS), and Euclidean Distance Similarity (EDS)) were compared along with an artificial neural network (ANN) model. The performance was assessed using a 70–30 split based on precision, recall, F1-score, and execution time. The results indicate that EDS and CBS achieved the highest detection accuracy, with EDS being computationally more efficient (CBS was 2.22 times slower). These findings demonstrate that EDS and CBS are promising methods for the efficient detection of asbestos–cement roofing from multispectral imagery and can be extrapolated to the identification of other materials under similar spatial-resolution and data-quality conditions.

**Keywords:** Asbestos-cement, multispectral images, spectral similarity, artificial neural networks.

## 1. INTRODUCCIÓN

El sensado remoto es una técnica consistente en la identificación, medición y análisis de las características de objetos o áreas de la superficie terrestre, sin entrar en contacto directo y haciendo uso de la detección y registro de la energía electromagnética o emitida por estos [1], [2]. Para lo anterior, el sensado remoto hace uso de sensores instalados en satélites, aviones o drones, los cuales operan en diferentes partes del espectro electromagnético (visible, infrarrojo, microondas, etc.) [3], [4]. En comparación con los métodos tradicionales, el sensado remoto ofrece diferentes ventajas en el monitoreo ambiental, de tal modo que permite la monitorización de grandes extensiones de terreno en poco tiempo sin requerir contacto físico con el área de estudio, lo que facilita la observación continua y el seguimiento de cambios a lo largo del tiempo [5]–[8].

Dentro de las técnicas más difundidas del sensado remoto, se destacan las imágenes espectrales, las cuales pueden definirse como aquellas que capturan información de una escena en múltiples bandas del espectro electromagnético permitiendo analizar la composición y las características de los objetos observados, de tal modo son consideradas «datacubos» al organizar la información en tres dimensiones: dos dimensiones espaciales (x,y) y una dimensión espectral (longitud e onda) [9]–[11]. Las imágenes espectrales incluyen tanto las imágenes multiespectrales que contienen decenas de bandas, como las imágenes hiperespectrales que incluyen cientos de bandas, de tal modo que en ambos casos estas imágenes proporcionan información detallada sobre la reflectancia o emisión de los materiales en diferentes longitudes de onda [12].

Son diferentes las investigaciones que se han realizado en el campo de las imágenes espectrales. Así en [13] se hizo uso de modelos soportados en redes neuronales convolucionales para la detección de asbesto-cemento sobre imágenes aéreas RGB y NIR, obteniendo precisiones en la detección del 89%, validando la

utilidad de estos métodos en inventarios a gran escala. Del mismo modo en [14] se realizó el mapeo cuantitativo de cubiertas de asbesto-cemento en una extensa región montañosa de los Alpes italianos de 3263 km<sup>2</sup> usando imágenes multiespectrales obtenidas a partir del sensor MVIDIS, logrando una precisión en la detección del 80% y concluyendo que la resolución espacial de los datos constituyen la principal fuente de errores en la detección. De otra parte, en [15]–[17] se hizo uso de imágenes hiperespectrales en el rango SWIR (1100–2500 nm) para la detección de asbesto en matrices de cemento, haciendo uso de modelos como SIMCA y PLS-DA, demostrando una alta sensibilidad y especificidad (0,89–1,00) en la detección. Así mismo, en [18] se evaluó el uso de Mask R-CNN con imágenes satelitales multiespectrales (MSSI) e imágenes aéreas de alta resolución (HRAI) para la detección de techos de fibrocemento en edificaciones residenciales australianas, obteniendo una precisión en la detección del 94% y un umbral de confianza del 99.8%. Por otra parte, en [19] se hizo uso de imágenes hiperespectrales y del software ENVI para el mapeo y diagnóstico del estado de techos de asbesto-cemento en el área urbana de la ciudad de Cartagena de Indias, identificando que hasta el 47% de la superficie de algunos barrios estaba cubierta por este material, con un promedio del 20% a nivel de barrio y más de 9 km<sup>2</sup> en toda la ciudad. En este mismo sentido, en [20] se evaluó la efectividad de un método computacional basado en la identificación de picos prominentes en la curva espectral de asbesto-cemento, evaluando dicho método con efectividad en imágenes hiperespectrales de 380 bandas de Cartagena de Indias.

Ahora bien a nivel de los desafíos de las imágenes hiperespectrales, se destaca en primer lugar que al contener cientos de bandas espectrales, generan datacubos con gran volumen de información que dificultan su análisis, por lo que para entornos de memoria limitada, suelen requerir para el procesamiento el uso de técnicas de particionamiento y almacenamiento eficientes [21]–[23]. En ese mismo sentido, el procesamiento de estas imágenes mediante métodos complejos, como los de aprendizaje profundo (deep learning), demanda un gran poder y costo

computacional, de tal modo que el uso de estos métodos no es adecuado para aplicaciones de monitorización en tiempo real [24]-[26]. De este modo, en este contexto, es necesario contar con modelos más ligeros o hacer uso de técnicas de reducción de dimensionalidad para equilibrar la precisión y la velocidad de la detección [27], [28]. En este mismo sentido, en lo que respecta a las imágenes multiespectrales, teniendo en cuenta que el número de bandas es reducido con respecto a las imágenes hiperespectrales, se dificulta la identificación precisa de materiales con firmas espectrales similares [29]-[31]. En este mismo sentido, mediante el uso de imágenes multiespectrales, es compleja la identificación de materiales en mezclas complejas o en capas superpuestas, dado que la firma espectral puede ser una combinación de varios materiales [29].

Teniendo en cuenta los desafíos a nivel de procesamiento y análisis de la gran cantidad de datos contenidos en las imágenes hiperespectrales y el desafío de las imágenes multiespectrales de permitir la detección de materiales mediante pocas bandas, en este artículo se propone como primera contribución la evaluación de métodos basados en similitud espectral (correlación (CBS), similitud diferencial espectral (SDS), distancia euclidiana (EDS) y redes neuronales artificiales (ANN) en la detección de asbesto-cemento en imágenes multiespectrales tipo NIR de 4 bandas pertenecientes a la ciudad de Cartagena de Indias. Así mismo se propone la evaluación de estos cuatro métodos, sobre una nueva versión de las imágenes en las cuales se agregó una nueva banda o capa correspondiente a la componente principal de PCA (Análisis de Componentes Principales) de la imagen, de cara a identificar si se presenta mejora en las capacidades de detección de cada uno de los métodos evaluados. De este modo, dado el menor costo económico en la adquisición de imágenes NIR, así como el menor costo computacional en el procesamiento de las mismas, este trabajo presenta una alternativa competitiva para la identificación de techos con presencia de asbesto, lo cual es de gran interés para las autoridades gubernamentales en Colombia y en otros países en vía de desarrollo de cara a la mitigación de los efectos nocivos de este material para la salud humana. Así mismo, este trabajo pretende ser replicado y extrapolado a nivel académico y empresarial en cuanto a la evaluación de estos métodos en la detección de otros materiales, aprovechando la técnica de enriquecimiento de la imagen NIR mediante una quinta banda derivada de la componente principal de PCA.

Estudios recientes han explorado el uso de redes neuronales convolucionales ligeras (CNN), máquinas de vectores de soporte (SVM) y métodos clásicos basados en ángulos espectrales, como SAM y SID, para la detección de materiales en cubiertas y la clasificación multiespectral en general. Las CNN

ligeras suelen alcanzar un alto desempeño al incorporar información espacial, sin embargo, dependen de conjuntos de datos anotados de mayor tamaño, técnicas de aumento de datos y esquemas de entrenamiento orientados al uso de GPU [32], [33].

Por su parte, las SVM han sido ampliamente empleadas en la clasificación multiespectral e hiperespectral debido a su robustez frente a tamaños de muestra reducidos, aunque generalmente requieren un ajuste cuidadoso de hiperparámetros y no ofrecen una interpretabilidad espectral explícita [34]. Los métodos SAM y SID continúan siendo utilizados como referencias debido a su estabilidad y a su comportamiento espectral bien comprendido, no obstante, su desempeño tiende a disminuir cuando el número de bandas espectrales disponibles es limitado [35].

En este mismo sentido, la validación independiente constituye una práctica habitual en aplicaciones de teledetección, especialmente cuando la confiabilidad de los datos de referencia en terreno es incierta. Estas estrategias suelen apoyarse en campañas de levantamiento en campo, capas catastrales auxiliares o imágenes de referencia de alta resolución, con el fin de realizar la verificación cruzada de materiales de cubierta o de tipos de cobertura del suelo [36]. En este contexto, el conjunto de datos fue cuidadosamente depurado mediante inspección visual y muestreo controlado, con el propósito de garantizar su consistencia interna y su adecuada interpretabilidad.

En este marco, el presente trabajo contribuye mediante la comparación sistemática de tres medidas de similitud espectral (CBS, SDS y EDS) frente a una red neuronal artificial simple, empleando únicamente cuatro bandas espectrales y un componente derivado de PCA. Esta comparación proporciona una línea base realista para escenarios multiespectrales aéreas de bajo número de bandas, en los cuales el uso de sensores hiperespectrales avanzados, extensos datos de referencia en campo o arquitecturas intensivas en GPU no resulta viable.

En estudios recientes sobre la detección de materiales en techos, la mayoría de los enfoques se basan en sensores hiperespectrales o en modelos computacionalmente intensivos, tales como arquitecturas basadas en redes neuronales convolucionales (CNN) y clasificadores espectrales de alta dimensionalidad. Estos métodos suelen requerir grandes volúmenes de datos, sistemas de adquisición especializados o módulos de procesamiento orientados al uso de GPU. En contraste, el presente trabajo se centra en un enfoque multiespectral ligero y de bajo número de bandas, empleando únicamente cuatro bandas espectrales (R, G, B y NIR), junto con un

componente adicional derivado mediante análisis de componentes principales (PCA).

Así, la contribución principal de este artículo radica en la comparación de tres medidas de similitud espectral (CBS, SDS y EDS) frente a una red neuronal artificial de estructura sencilla, utilizando un conjunto de datos reducido y completamente interpretable, obtenido a partir de estructuras urbanas reales. El estudio pone en relieve la eficiencia computacional, la reproducibilidad y la viabilidad práctica de implementar estos métodos dentro de flujos de trabajo de bajo costo, en contextos donde no se dispone de sensores hiperspectrales de alta gama. Este aspecto resulta particularmente relevante para países en desarrollo como Colombia, donde el asbesto ha sido recientemente prohibido y se requiere con urgencia la evaluación a gran escala de cubiertas de asbesto-cemento.

El resto del artículo está organizado de la siguiente forma: En la sección 2 se presentan las fases metodológicas que guiaron el desarrollo de la presente investigación. En la fase 3 se presentan los resultados derivados de esta investigación, lo cual incluye en primera instancia el ajuste y evaluación de la capacidad de detección de los 4 métodos con firmas espectrales de muestra de asbesto-cemento y de otros materiales derivadas a partir de imágenes de 4 y 5 bandas. Así mismo se incluye el despliegue de los 4 métodos sobre una imagen NIR de zonas aledañas al cerro de la Popa en Cartagena, verificando visualmente las zonas detectadas por cada método. De otra parte, también se incluye la evaluación de la eficiencia computacional de cada método en el procesamiento y análisis de una región de la imagen de 30x30 píxeles, en donde cada píxel tiene 5 bandas espectrales. Finalmente, en la sección 4 se incluyen las conclusiones y los trabajos futuros derivados de la presente investigación.


## 2. METODOLOGÍA

Para el desarrollo de la presente investigación, se hizo una adaptación a cuatro fases de la metodología CRISP-DM: F1. Entendimiento del negocio y de los datos, F2. Preparación de los datos, F3. Modelado y evaluación, F4. Despliegue de los modelos (ver Figura 1).

Se escogió la metodología CRISP-DM, teniendo en cuenta que su clara estructura en fases estandarizadas, facilita la organización y comprensión del ciclo de vida de los proyectos de ciencias de datos, permitiendo una gestión clara desde la comprensión del problema hasta la implementación, despliegue y mantenimiento de modelos [37]-[39].

Así mismo, cabe destacar que la metodología CRISP-DM es altamente adaptable y puede ser integrada con enfoques ágiles o ser personalizada para contextos de

aplicación específicos, como es el caso de la visión por computador [40].



**Fig. 1. Metodología considerada.**

**Fuente:** elaboración propia.

En la fase 1 de la metodología, a partir de una imagen multiespectral aérea de referencia de  $3000 \times 3000$  píxeles y cuatro bandas espectrales de reflectancia (rojo, verde, azul e infrarrojo cercano), se seleccionaron por inspección visual y validación de campo en total 600 píxeles o firmas espectrales de muestra, de los cuales 300 correspondieron a cubiertas de asbesto-cemento y 300 a otros materiales. Las imágenes aéreas multiespectrales empleadas en este estudio fueron obtenidas a partir de conjuntos de datos de acceso público publicados por el Establecimiento Público Ambiental (EPA) de Cartagena y, aunque su cobertura abarca la totalidad del área urbana de la ciudad, el análisis se centró específicamente en la región correspondiente al Cerro de La Popa. De acuerdo con la información técnica asociada a los datos publicados, las imágenes fueron sometidas previamente a procesos de remuestreo espacial y corrección radiométrica, por lo que el análisis se realizó directamente utilizando la resolución espacial estandarizada y los valores radiométricos corregidos proporcionados en el conjunto de datos. El procedimiento descrito fue igualmente aplicado sobre una imagen equivalente de cinco bandas espectrales, donde la quinta banda incorporada fue obtenida a partir de la primera componente principal derivada de la aplicación del análisis de componentes principales (PCA) sobre la imagen original de cuatro bandas.

Cabe mencionar que el preprocesamiento de las imágenes consistió en la conversión de los archivos fuente en un cubo de datos multiespectral estructurado, la eliminación de valores atípicos evidentes y la normalización independiente de cada banda espectral con el fin de reducir la variabilidad asociada a las condiciones de iluminación. Como se mencionó previamente, también se generó una versión del conjunto de datos con cinco bandas mediante el cálculo y la incorporación del primer componente principal normalizado obtenido a partir del análisis de componentes principales (PCA). Estos procedimientos garantizaron representaciones de entrada consistentes tanto para las medidas de similitud espectral como para el modelo de red neuronal artificial. Dada la ausencia de registros de calibración radiométrica absoluta, el estudio se centra en el análisis del comportamiento




espectral relativo, en lugar de valores absolutos de reflectancia.

La selección de las 600 firmas espectrales utilizadas en este trabajo siguió un procedimiento estructurado y validado en campo. La identificación de cubiertas de asbesto-cemento (AC) se fundamentó en un marco metodológico adaptado de estudios previos [41] y ajustado a las características específicas del conjunto de datos analizado. En dicho estudio previo, desarrollado en el área urbana de Cartagena, se recolectaron muestras físicas de cubiertas ( $1 \times 1$  cm) provenientes de edificaciones representativas, las cuales fueron analizadas mediante microscopía de luz polarizada (PLM), conforme a la norma ASTM D7521-22, con el fin de confirmar la presencia de fibras de asbesto. Estas cubiertas de asbesto-cemento verificadas sirvieron como ubicaciones de referencia para la caracterización espectral y el etiquetado de clases en el presente estudio. Las demás clases de materiales de cubierta fueron delimitadas mediante interpretación visual detallada y verificación en campo. Cada cubierta muestreada fue georreferenciada mediante coordenadas GPS y, cuando estuvo disponible, respaldada por información catastral auxiliar, como límites prediales y huellas de edificación, con el propósito de garantizar la coherencia espacial y material de las muestras.

El mismo conjunto de ubicaciones espaciales fue utilizado tanto para el conjunto de datos de cuatro bandas como para el de cinco bandas, con el fin de preservar la consistencia entre los experimentos. De este modo, en la fase 1 se conformaron dos conjuntos de datos independientes, uno correspondiente a la imagen de cuatro bandas y otro a la imagen de cinco bandas, cada uno compuesto por 300 píxeles de muestra y subdividido en dos clases: asbesto-cemento y otros materiales. La estabilidad de las respuestas espectrales y los bajos niveles de ruido presentes en las imágenes permitieron la extracción de firmas espectrales consistentes y reproducibles para el posterior análisis.


Estos píxeles o firmas espectrales de muestra fueron usados para ajustar y evaluar los 4 métodos considerados en este artículo de cara a identificar la capacidad de detección de cada método y en el caso de los métodos de similitud espectral, determinar los umbrales de referencia a partir de los cuales los métodos detectan el material. Cabe mencionar que para la conversión de la imagen del formato tif a un datacubo o arreglo de tres dimensiones se hizo uso de las ventajas de la librería rasterio de Python, la cual permite convertir el datacubo original en un arreglo multidimensional del tipo de la librería numpy de Python.

A partir de lo anterior, en la Figura 2 se presenta sobre una representación RGB de la imagen multispectral de zonas aledañas del cerro de la Popa, la ubicación de los píxeles de muestra seleccionados, en donde en color azul se muestran los píxeles de asbesto-cemento y en color rojo se muestran los píxeles de otros materiales.



**Fig. 2.** Píxeles de muestra de asbesto-cemento y de otros materiales. **Fuente:** elaboración propia.


En este mismo sentido, en la Figura 3 se presentan a partir de los 600 puntos de referencia, las 300 firmas espectrales de asbesto-cemento y las 300 firmas de otros materiales, obtenidas de la imagen de 4 bandas espectrales.



**Fig. 3.** Firmas espectrales de los píxeles de 4 bandas. **Fuente:** elaboración propia.

De otra parte, en la Figura 4 se presenta a partir de los mismos 600 puntos de muestra, las 300 firmas

espectrales de asbesto-cemento y las 300 firmas de otros materiales, obtenidas de la imagen de 5 bandas espectrales.



**Fig. 4.** Firmas espectrales de los píxeles de 5 bandas.  
**Fuente:** elaboración propia.

Así mismo, en la fase 2 de la metodología se procedió para el caso de los 3 métodos basados en similitud espectral con el cálculo de las firmas espectrales promedio o firmas espectrales características asociadas a los píxeles de muestra de asbesto-cemento de 4 y 5 bandas. Lo anterior fue realizado mediante el uso de las ventajas provistas de la librería numpy, la cual permite el cálculo banda a banda del promedio de reflectancia, obteniendo así las dos firmas espectrales promedio de 4 y 5 bandas respectivamente.

Estas dos firmas fueron usadas posteriormente para calcular la similitud con los dos grupos de píxeles de muestra y determinar los umbrales de detección y la capacidad de detección de los métodos de similitud espectral. Ahora bien, en lo que respecta al modelo de redes neuronales artificiales ANN, se procedió con la conformación de 2 datasets derivados del etiquetado de las firmas espectrales de muestra de 4 y 5 bandas respectivamente.

En consecuencia, el conjunto de datos final quedó conformado por 300 registros correspondientes a firmas espectrales de cubiertas de asbesto-cemento, etiquetadas como clase 1, y 300 registros correspondientes a firmas espectrales de otros materiales, etiquetadas como clase 0. Dicho dataset fue empleado para el entrenamiento, ajuste de hiperparámetros y evaluación del desempeño del modelo de red neuronal artificial (ANN).

Para el modelo de red neuronal artificial (ANN), el conjunto de datos fue dividido en un conjunto de entrenamiento y un conjunto de prueba siguiendo una proporción 70/30. Dado el número limitado de columnas disponibles en el dataset, el modelo ANN fue incorporado únicamente como una línea base ligera, y no como un clasificador plenamente generalizable. No se aplicó un esquema de validación cruzada, ya que el objetivo del estudio no fue optimizar un modelo de aprendizaje de alta capacidad, sino comparar su comportamiento frente a los métodos de similitud espectral bajo las mismas condiciones de entrada reducidas.

Cabe mencionar adicionalmente que, aunque la selección 300 muestras de asbesto-cemento podría interpretarse como una limitación, dichos puntos pertenecen a un mismo material con características homogéneas y, por tanto, presentan firmas espectrales altamente similares, lo que hace innecesaria la recolección de miles de muestras de este material. No obstante, una de las posibles limitaciones a la hora de extrapolar este estudio radica en la identificación, mediante visitas de campo, de zonas adecuadas donde el material se encuentre presente y sea posible obtener muestras representativas.

Del mismo modo, en la fase 3 de la metodología, se procedió en primera instancia con la implementación y evaluación de los 3 métodos de similitud basados en correlación, similitud diferencial espectral y distancia euclidiana con los dos grupos de píxeles de muestra tanto de 4, como de 5 bandas, de cara a identificar la capacidad de detección de cada método y por ende los umbrales mínimos de detección, verificando que el porcentaje de similitud mínima con píxeles de asbesto-cemento, sea superior al porcentaje de similitud máxima con otros materiales. Estos umbrales son claves para ser usados en el despliegue de los métodos de similitud espectral sobre el total de la imagen, de tal modo que permiten indicar los niveles desde los cuales estos métodos clasifican los píxeles como de asbesto-cemento. De manera específica, la ecuación matemática que representa la similitud basada en correlación (CBS) y que fue implementada en esta fase es presentada en (1), donde  $r$  es la correlación normalizada de Pearson, la cual al ser calculada por la librería SciPy de Python se encuentra en el rango de 0 a 2 y determina el grado de similitud entre los patrones o tendencias de dos arreglos, en este caso los píxeles espectrales correlacionados.

$$CBS = \left( \frac{r + 1}{2} \right) \times 100 \quad (1)$$

Del mismo modo, la ecuación (2) representa la similitud diferencial espectral (SDS), en donde  $X_i$  e  $Y_i$  corresponden a los dos arreglos comparados, siendo en este caso el píxel promedio y un píxel específico de la

imagen. Por su parte N corresponde al número de bandas de la imagen, en este caso 4 o 5. De este modo la SDS realiza la sumatoria de las diferencias de las reflectancias banda a banda de los dos arreglos, de modo que cuanto más pequeña sea la diferencia, más parecidos son los arreglos o firmas espectrales comparadas.

$$SDS = 100 - \left( \frac{\sum (X_i - Y_i)}{N} \right) \times 100 \quad (2)$$

De otra parte, la ecuación (3) representa la similitud espectral basada en la distancia euclidiana (EDS), donde  $X_i$  e  $Y_i$  son los arreglos comparados y previamente normalizados, mientras que ED es la distancia euclidiana normalizada de los arreglos  $X_i$  e  $Y_i$ . La ED mide la distancia en línea recta entre dos arreglos espectrales en un espacio N-dimensional, donde N es el número de bandas espectrales.

$$EDS = \left( 1 - \frac{ED(X_i, Y_i)}{\sqrt{2}} \right) \times 100 \quad (3)$$

Ahora bien, en lo que respecta al modelo ANN, en esta fase se realizó el diseño e implementación mediante la librería tensorflow de Python de la arquitectura de los modelos a aplicar sobre el dataset de 6 bandas y el dataset de 7 bandas, evaluando su rendimiento en 100 épocas, tomando como referencia la métrica de accuracy. Cabe mencionar que las arquitecturas fueron evaluadas de manera iterativa hasta obtener los resultados más consistentes y con mejor rendimiento en los conjuntos de entrenamiento y prueba. De manera específica, la ecuación (4) representa matemáticamente la arquitectura de la red neuronal artificial (ANN), donde  $X_i$  representa las entradas de la neurona,  $w_i$  corresponde a los pesos asociados a cada entrada,  $b$  es el término de polarización o sesgo,  $f$  es la función de activación (tales como ReLU, tanh, sigmoide) y  $\hat{y}$  es la salida estimada generada por la neurona.

$$\hat{y} = f \left( \sum_{i=1}^n \omega_i x_i + b \right) \quad (4)$$

Finalmente, una vez fue identificada la capacidad de ajuste de cada uno de los métodos, en la fase 4 de la metodología se procedió con el despliegue de cada uno de los cuatro métodos considerados sobre las imágenes multiespectrales de 4 y 5 bandas de reflectancia, haciendo uso de los umbrales detectados en la fase 3 para el caso de los métodos de similitud espectral, de cara a obtener el porcentaje de asbesto-cemento en cada método y comparar visualmente las zonas detectadas en cada caso. Así mismo, en esta fase se comparó la eficiencia computacional de cada uno de los métodos al ejecutarlos sobre una región de la imagen de 30x30 píxeles y 5 bandas de reflectancia en un diferente número de repeticiones: 25, 50, 75 y 100,

de cara a obtener el tiempo promedio de procesamiento por repetición y el tiempo promedio total de procesamiento, el cual fue usado para evaluar la eficiencia computacional relativa entre los métodos.


De este modo, con el fin de garantizar que los resultados de tiempo de ejecución no se vieran afectados por la variabilidad asociada a una sola ejecución, cada método fue ejecutado múltiples veces sobre la misma región de imagen de 30 x 30 píxeles y cinco bandas espectrales. Se emplearon cuatro niveles de repetición (25, 50, 75 y 100 ejecuciones), y los valores reportados corresponden al tiempo promedio de procesamiento obtenido a partir de dichas repeticiones. Este enfoque de repetición proporciona una medida básica de estabilidad temporal, aun cuando no se reportan intervalos de confianza, dado que el objetivo principal de este experimento fue comparar la eficiencia relativa de los métodos más que realizar un análisis estadístico exhaustivo del desempeño.

Todos los experimentos fueron llevados a cabo en un entorno de cómputo académico utilizando Google Colab, ejecutado sobre un sistema operativo basado en Linux con 12.7 GB de memoria RAM disponible. No se empleó aceleración por GPU. Esta descripción del entorno de ejecución se incluye con el propósito de contextualizar las comparaciones de tiempo, las cuales reflejan diferencias relativas entre los métodos y no tiempos absolutos de ejecución.

Los tiempos de procesamiento fueron medidos utilizando el módulo time incorporado en Python, el cual registra la duración en tiempo real requerida para cada ejecución. Únicamente se incluyó en la medición el cómputo central de cada algoritmo; las etapas de carga de datos y preprocesamiento fueron excluidas con el fin de evitar sesgos en la comparación.

### 3. RESULTADOS Y DISCUSIÓN

A nivel de los resultados, en primer lugar, se obtuvieron las firmas espectrales promedio de los píxeles de muestra de asbesto-cemento de 4 y 5 bandas, las cuales se presentan en la Figura 5. Estas firmas fueron usadas para evaluar la capacidad de detección de asbesto-cemento por parte de los 3 métodos de similitud espectral en los dos grupos de píxeles de muestra tanto de 4, como de 5 bandas de reflectancia.



**Fig. 5.** Firma espectral promedio obtenida para los píxeles de muestra de 4 y 5 bandas. **Fuente:** elaboración propia.

Del mismo modo, en lo que respecta al modelo ANN, fueron estructurados dos datasets de 600 instancias, cada uno asociado a los píxeles de muestra de 4 y 5 bandas. De este modo, el primer dataset cuenta con 600 instancias de 5 columnas, las primeras cuatro correspondientes a los valores de reflectancia (bandas RGB y banda NIR) y la última columna correspondiente a la etiqueta asociada al tipo de píxel, 1 para píxeles de asbesto-cemento y 0 para píxeles de otros materiales. Del mismo modo, el segundo dataset, quedó conformado por 6 columnas, las primeras 5 columnas correspondientes a los valores de reflectancia de las 4 bandas del primer dataset y una banda adicional asociada al primer componente principal de PCA aplicado a la imagen. De otra parte, la sexta columna corresponde a la etiqueta asociada al tipo de píxel, al igual que en el primer dataset. De este modo, en la Figura 6 se muestra la estructura del segundo dataset, el cual como se mencionó incluye además de la información del primer dataset una banda adicional.

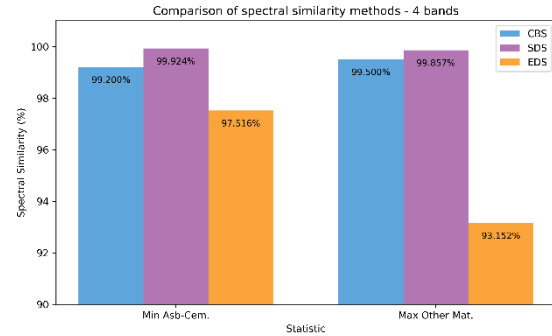
	band1	band2	band3	band4	pixel
0	0.396078	0.352941	0.380392	0.513725	1.0
1	0.407843	0.360784	0.380392	0.509804	1.0
2	0.396078	0.368627	0.400000	0.517647	1.0
3	0.403922	0.352941	0.380392	0.501961	1.0
4	0.403922	0.368627	0.400000	0.513725	1.0
...	...	...	...	...	...
595	0.215686	0.239216	0.207843	0.800000	0.0
596	0.180392	0.227451	0.152941	0.745098	0.0
597	0.168627	0.192157	0.168627	0.713725	0.0
598	0.254902	0.298039	0.196078	0.819608	0.0
599	0.270588	0.313725	0.258824	0.796078	0.0

600 rows × 5 columns

**Fig. 6.** Dataset obtenido para la imagen de 5 bandas.

*Fuente:* elaboración propia.

Ahora bien, partiendo de las firmas espectrales promedio obtenidas de los píxeles de muestra de asbesto-cemento de 4 y 5 bandas, se procedió con la implementación y evaluación de los 3 métodos de similitud espectral considerados: CBS, SDS y EDS, en los cuales se determinó de 3 maneras matemáticas diferentes que tan similares son las firmas espectrales características de 4 y 5 bandas a los dos grupos de píxeles de muestra. Como se mencionó previamente, los tres métodos fueron implementados a partir de las ventajas provistas para operaciones matemáticas entre arreglos de las librerías scipy y numpy. De este modo, en la Figura 7, se presentan los resultados comparativos obtenidos por los 3 métodos de similitud espectral con los 2 grupos de píxeles de 4 bandas de reflectancia.



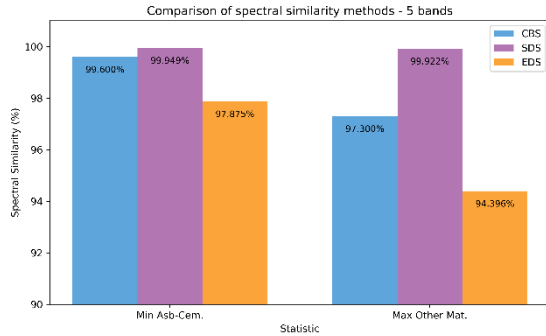
**Fig. 7.** Comparación de métodos de similitud espectral con píxeles de muestra de 4 bandas.

*Fuente:* elaboración propia.

De acuerdo con los resultados presentados en la Figura 7, es posible apreciar como para los píxeles de muestra de 4 bandas, el único método que presenta traslape es el de CBS, es decir que el porcentaje de similitud espectral mínima con los 300 píxeles de muestra de asbesto-cemento, no es mayor que el porcentaje de similitud máxima con píxeles de otros materiales. Así mismo, se observa que los métodos de SDS y EDS no presentan traslape y permiten diferenciar de manera más clara la firma espectral característica de asbesto-cemento de las de otros materiales, de tal modo que la diferencia entre umbrales es de 0.067% para SDS y de 4.364% para EDS. En este sentido, también es posible observar que, aunque el método de SDS tiene el porcentaje de similitud mínima más alto del grupo, el método de EDS es el que brinda una mayor diferenciación de la firma espectral con respecto a los píxeles de muestra de otros materiales.

De otra parte, en la Figura 8 son presentados los resultados comparativos obtenidos por los 3 métodos de similitud espectral con los dos grupos de píxeles de 5 bandas de reflectancia, donde se aprecia que a diferencia de lo ocurrido con la evaluación con los píxeles de muestra de 4 bandas, los 3 métodos considerados no presentan traslape, es decir que en los 3 casos la similitud mínima con píxeles de asbesto-cemento es mayor que la similitud máxima con píxeles de otros materiales. Así mismo, es posible observar como para el caso del método de la CBS, la diferencia entre los dos umbrales pasó de ser negativa a ser del 2.3%, mientras que para los métodos de SDS y EDS la diferencia decreció levemente y de manera respectiva de 0.067% a 0.027% y de 4.364% a 3.479%. Así, aunque con la banda adicional disminuye levemente la capacidad de detección de los métodos SDS y EDS, el método de CBS permite diferenciar de manera clara la firma espectral característica de los píxeles de otros materiales, obteniendo un porcentaje de diferencia entre los umbrales de 2.3%.

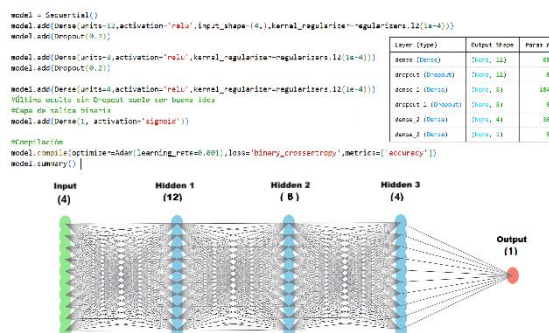




**Fig. 8.** Comparación de métodos de similitud espectral con píxeles de muestra de 5 bandas. **Fuente:** elaboración propia.

De acuerdo con lo anterior, aunque el método de la correlación mejoró con las 5 bandas en cuanto a la capacidad de diferenciar la firma espectral de asbesto cemento de los píxeles de otros materiales, el método de la EDS sigue siendo el que presenta una mayor diferencia en los umbrales y por tanto es el que mejor capacidad de detección brinda con los píxeles de muestra.

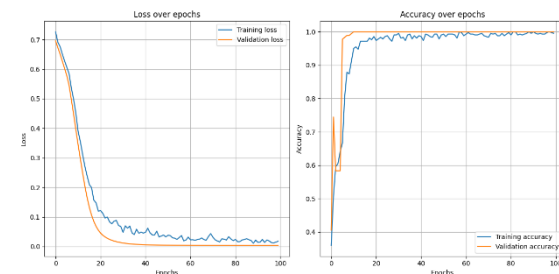
Ahora bien, continuando con el modelo de ANN, se procedió con el diseño de la arquitectura y el ajuste de la misma con los conjuntos de entrenamiento y prueba derivados del dataset de 4 bandas de reflectancia, obteniendo que el mejor ajuste ocurre cuando el modelo secuencial se estructura con una capa de entrada de 4 neuronas, una capa de salida de 1 neurona por la naturaleza binaria del problema, y 3 capas ocultas de 12, 8 y 4 neuronas. Se utilizaron funciones de activación ReLU en las capas ocultas y una función Sigmoid en la capa de salida. Para la regularización, se aplicó una capa de Dropout con una tasa del 20% después de cada capa, incluyendo la de entrada y las capas ocultas, para prevenir el sobreajuste. El modelo se compiló utilizando el optimizador Adam con una tasa de aprendizaje de 0.001, y se empleó 'binary\_crossentropy' como función de pérdida, adecuada para la clasificación binaria, junto con la métrica 'accuracy' como métrica principal para evaluar el rendimiento. Así, en la Figura 9 se presenta la estructura del modelo ANN y el código de implementación en TensorFlow.



**Fig. 8.** Estructura de la ANN para el dataset de 4 bandas espectrales. **Fuente:** elaboración propia.

Del mismo modo, para el caso del dataset de 5 bandas, se obtuvo una estructura similar para el modelo ANN, de tal modo que en este caso se tiene una capa de entrada con 5 neuronas, una capa de salida con una neurona dada la naturaleza binaria del problema y tres capas ocultas con 12, 8, y 4 neuronas, dejando los demás parámetros y funciones iguales al modelo ANN para el dataset de 4 bandas.

La estructura de los modelos fue evaluada de manera iterativa en 100 épocas con el conjunto de entrenamiento y prueba de los datasets de 4 y 5 bandas, de tal modo que para el modelo ANN asociado al dataset de 4 bandas y presentado en la Figura 8, se obtuvo como resultado tanto el rendimiento a partir de la métrica de accuracy, como las pérdidas en las diferentes épocas en entrenamiento como en evaluación, tal como se presenta en la Figura 9.




**Fig. 9.** Rendimiento del modelo ANN del dataset de 4 bandas.

**Fuente:** elaboración propia.

A partir de la Figura 9 se observa que la pérdida de entrenamiento presenta una disminución pronunciada durante las primeras épocas, estabilizándose progresivamente en valores cercanos a 0.05 a partir de aproximadamente la época 40, con ligeras oscilaciones propias del proceso de optimización. De forma similar, la pérdida de validación decrece de manera consistente y se mantiene en valores comparables, ligeramente inferiores a los de entrenamiento, lo que sugiere una adecuada convergencia del modelo sin evidencias de sobreajuste. En cuanto a la métrica de accuracy, la precisión de entrenamiento aumenta rápidamente y alcanza valores superiores a 0.95 alrededor de las primeras 15–20 épocas, estabilizándose posteriormente cerca de 1.0. La precisión de validación sigue una tendencia muy similar, alcanzando valores cercanos a la unidad en etapas tempranas del entrenamiento, lo que indica un alto nivel de desempeño y una notable capacidad de generalización del modelo ANN sobre el dataset de 4 bandas evaluado.

Del mismo modo, en lo que concierne a la evaluación del modelo ANN de 5 bandas, en la Figura 10 se presentan los resultados de las pérdidas y el rendimiento del modelo a 100 épocas en el conjunto de entrenamiento y de prueba.




**Fig. 10.** Rendimiento del modelo ANN del dataset de 5 bandas.  
**Fuente:** elaboración propia.

De acuerdo con la Figura 10 se observa que la pérdida de entrenamiento del modelo ANN entrenado con el dataset de 5 bandas espectrales presenta una disminución rápida y pronunciada durante las primeras épocas, estabilizándose progresivamente en valores cercanos a 0.03–0.05 a partir de aproximadamente la época 35–40, con ligeras oscilaciones asociadas al proceso iterativo de optimización. De manera consistente, la pérdida de validación sigue una tendencia similar, alcanzando valores ligeramente inferiores a los de entrenamiento y manteniéndose estable a lo largo del entrenamiento, lo cual sugiere una adecuada convergencia del modelo sin indicios de sobreajuste.

En lo que respecta a la métrica de accuracy, la precisión de entrenamiento aumenta de forma acelerada y supera valores de 0.95 en las primeras 15–20 épocas, estabilizándose posteriormente en valores cercanos a la unidad. La precisión de validación muestra un comportamiento prácticamente idéntico, alcanzando valores próximos a 1.0 en etapas tempranas del entrenamiento, lo que evidencia un alto nivel de desempeño y una destacable capacidad de generalización del modelo ANN al incorporar información espectral adicional en el dataset de 5 bandas. Así, en comparación con el modelo entrenado con el dataset de 4 bandas, la inclusión de la banda adicional se traduce en una convergencia ligeramente más rápida y en una mayor estabilidad tanto en la pérdida como en la precisión, sugiriendo un beneficio marginal en el proceso de aprendizaje del modelo.

En este mismo sentido, en la Figura 11 se presenta el rendimiento alcanzado en promedio por el modelo ANN en las últimas 20 épocas de las 100 consideradas, a nivel de las métricas derivadas de la matriz de confusión, tales como: precisión, recall y F1-score tanto para el dataset de 4 bandas, como para el dataset de 5 bandas.




**Fig. 11.** Métricas de rendimiento del modelo ANN para los datasets de 4 y 5 bandas.  
**Fuente:** elaboración propia.

A partir de los resultados presentados en la Figura 11, es posible apreciar que las tres métricas consideradas (precisión, recall y F1-score) alcanzan en ambos datasets valores superiores al 99%, lo que evidencia un desempeño globalmente alto y consistente de los modelos evaluados. De manera particular, el modelo de ANN entrenado con el dataset de 4 bandas presenta un rendimiento levemente superior en las métricas de recall y F1-score, lo que sugiere una mayor capacidad para identificar correctamente la clase de interés y un mejor equilibrio entre precisión y exhaustividad.

Por su parte, el modelo de ANN evaluado sobre el dataset de 5 bandas exhibe un desempeño superior en la métrica de precisión, indicando una reducción en la proporción de falsos positivos, posiblemente asociada a la incorporación de información espectral adicional. No obstante, las diferencias observadas entre ambas configuraciones son marginales, lo que sugiere que el modelo ANN mantiene un comportamiento robusto frente a variaciones en el número de bandas espectrales consideradas.

Ahora bien, con el fin de desplegar los 3 métodos de similitud espectral y el modelo secuencial ANN sobre la imagen multiespectral completa de 4 bandas, se realizó la iteración por cada pixel de la imagen de 4 bandas y se realizó la clasificación de cada pixel en una representación RGB de la imagen multiespectral, luego de aplicar las operaciones de similitud y clasificación mediante los cuatro métodos. Así, en la Figura 12, se presenta en color azul los pixeles de asbesto detectados por cada uno de los cuatro métodos sobre una representación de la imagen RGB.

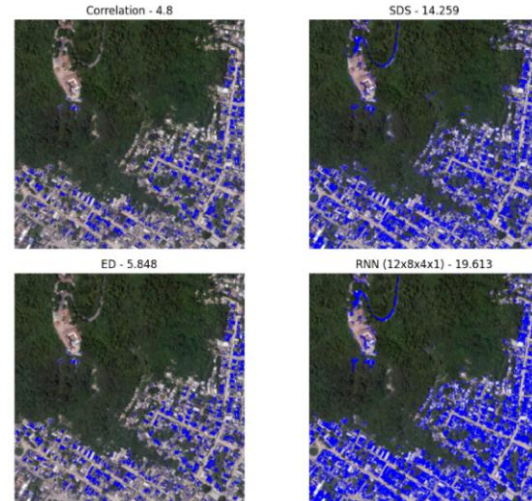


**Fig. 12.** Despliegue de los 4 métodos sobre la imagen multiespectral de 4 bandas.  
**Fuente:** elaboración propia.

A partir de los resultados presentados en la Figura 12, es posible apreciar de manera visual como los métodos de EDS y CBS son los que detectan de manera más precisa pixeles de asbesto-cemento en la imagen de 4 bandas, detectando respectivamente un porcentaje de pixeles de 6.89% y 5.639%. Del mismo modo se observa que el método de SDS aunque detecta cerca del doble de pixeles (13.083%) que los métodos de EDS y CBS, es posible apreciar como este método comete más errores en la detección, identificando pixeles de asbesto en la parte superior del cerro de la Popa, en donde no se evidencia la presencia de asbesto-cemento.

Así mismo, se aprecia que este método confunde más pixeles de carretera y vegetación que los métodos de CBS y EDS. Finalmente, aunque el modelo ANN obtuvo un buen rendimiento en el ajuste y es el que detecta una mayor cantidad de pixeles de asbesto con un 19.772%, es también el método que comete mayor cantidad de errores confundiendo pixeles de vegetación y de carreteras con pixeles de asbesto-cemento, haciendo que el porcentaje de pixeles de asbesto sea el más elevado de los 4 métodos.

Ahora bien, al realizar la implementación y el despliegue de los 4 métodos considerados sobre la imagen multiespectral con 5 bandas (4 bandas de reflectancia y una banda adicional obtenida a partir del análisis PCA), se realizó la clasificación de los pixeles de asbesto-cemento, de tal modo que en la Figura 13, se presenta en color azul los pixeles detectados de asbesto-cemento sobre una representación RGB de la imagen mediante el uso de los 4 métodos considerados.




**Fig. 13.** Despliegue de los 4 métodos sobre la imagen multiespectral de 5 bandas.  
**Fuente:** elaboración propia.

De acuerdo con los resultados presentados en la Figura 13, es posible apreciar como los métodos de EDS y CBS siguen presentando los mejores resultados a nivel de detección, incrementando levemente el porcentaje de detección para el caso del método de EDS y disminuyendo levemente el porcentaje de detección para el caso del método de CBS, con respecto a la detección realizada sobre la imagen de 4 bandas. Del mismo modo, en lo que respecta al método de la SDS, se obtuvo un porcentaje levemente superior con respecto a los resultados obtenidos con la imagen de 4 bandas, de tal modo que se siguen presentando errores en la parte superior del cerro de la Popa, así como confusión en los pixeles de vegetación y carretera. Así mismo, con respecto al modelo de ANN, se obtuvo que el porcentaje de detección bajo levemente con respecto a la imagen de 4 bandas, disminuyendo los errores de detección y por ende las confusiones de pixeles de vegetación y de carreteras con pixeles de asbesto-cemento. Así, mediante la inclusión de una banda adicional sobre la imagen de 4 bandas, los métodos de CBS y ANN refinan la detección, mientras que el método EDS presenta resultados similares en la detección y el método SDS disminuye levemente su capacidad de detección incrementando el número de errores.

Ahora bien, con el fin de evaluar comparativamente la eficiencia computacional de los 4 métodos considerados, se realizó el despliegue de los mismos en múltiples repeticiones (25,50,75 y 100) sobre una región de la imagen de 30x30 y 5 bandas espectrales, haciendo use de la librería timeit de Python y con el fin de identificar el tiempo de procesamiento por repetición, el tiempo de procesamiento promedio y la eficiencia relativa de los métodos. Así, en la Figura 14 se presenta un diagrama de líneas donde se muestra el



tiempo de procesamiento obtenido por cada uno de los métodos en las diferentes repeticiones.



**Fig. 13.** Comparación de la eficiencia computacional de los 4 métodos. *Fuente:* elaboración propia.

A partir de los resultados presentados en la Figura 14, es posible apreciar como el modelo de ANN es el que emplea en promedio un mayor tiempo en las diferentes repeticiones, de tal modo que en procesar la imagen de 30x30 píxeles y 5 bandas de reflectancia emplea como mínimo un tiempo de 92.8 milisegundos y como máximo un tiempo de 130.2 milisegundos. De otra parte, con respecto a los métodos de similitud espectral, el que en promedio es más eficiente es el de la SDS, seguido de cerca por el método EDS y con una diferencia mayor por parte del método CBS, sin que haya traslape en las curvas de los 3 métodos, es decir que el método de SDS tiene tiempos menores que el método EDS en las diferentes repeticiones, y a su vez el método EDS tiene tiempos menores en las diferentes repeticiones que el método CBS. Dado que los métodos con mayor eficacia en la detección fueron EDS y CBS, es importante comparar la eficiencia relativa entre ellos, teniendo en cuenta en primera instancia que el método EDS emplea en el procesamiento de la región de la imagen tiempos en promedio que varían entre los 9.5 y los 15.9 milisegundos, mientras que el método de la CBS emplea en promedio tiempos de procesamiento que varían entre los 20 y los 36 milisegundos. Ahora bien, al comparar el promedio general en las diferentes repeticiones de los métodos EDS y CBS, se obtiene que en promedio el método de CBS es 2.22 veces más lento que el método de EDS, lo que indica que en términos de reducción de tiempo el método EDS reduce en 54.76% el tiempo empleado por el método de CBS.

Ahora bien, a nivel de la discusión de los resultados obtenidos, cabe mencionar que en este trabajo se evaluó la viabilidad en el uso de métodos de similitud espectral y basados en redes neuronales secuenciales para la identificación de cubiertas de asbesto-cemento en imágenes multiespectrales de 4 bandas (RGB + NIR) y en imágenes NIR enriquecidas con una quinta banda correspondiente al primer componente PCA de la imagen. Así como resultado se obtuvo que los métodos de EDS y CBS fueron los que presentaron en

conjunto una mejor eficacia y eficiencia en la detección.

Así, en comparación con estudios previos, tales como [15]-[17], que se basan en el uso de imágenes hiperespectrales en el rango del infrarrojo de onda corta (SWIR), los resultados obtenidos en este trabajo evidencian el potencial de los datos multiespectrales de bajo número de bandas como una alternativa más simple para la detección exploratoria de materiales. De este modo, este enfoque representa un aporte relevante frente a investigaciones previas orientadas a la detección de asbesto-cemento mediante imágenes hiperespectrales, al demostrar que el uso de imágenes de cuatro o cinco bandas permite reducir de manera significativa tanto los costos computacionales de procesamiento como los costos asociados a la adquisición de datos, en comparación con aquellos requeridos para capturar y procesar imágenes compuestas por cientos de bandas espectrales. En este sentido, los métodos que mostraron mayor eficacia y eficiencia en este estudio presentan un alto potencial para ser articulados en entornos de monitorización en tiempo casi real de asbesto-cemento u otros materiales de interés ambiental, especialmente en escenarios donde el acceso a sensores hiperespectrales resulta limitado o inviable.

A pesar de lo anterior, estos hallazgos deben interpretarse a la luz del contexto geográfico y ambiental en el cual se llevaron a cabo los experimentos. El estudio se basa en datos provenientes de una única región, con características superficiales y condiciones atmosféricas específicas, así como en propiedades de imagen inherentes al conjunto de datos disponible. En consecuencia, los resultados obtenidos reflejan la factibilidad metodológica del enfoque propuesto bajo estas circunstancias particulares, más que un desempeño plenamente generalizable. Cualquier aplicación a mayor escala, ya sea en contextos de monitoreo operativo o empleando diferentes tipos de sensores y configuraciones ambientales, debe considerarse de carácter preliminar y sujeta a procesos de validación adicionales mediante conjuntos de datos más diversos y datos de referencia independientes.

En este mismo sentido, a partir del uso en la presente investigación de técnicas y tecnologías soportadas en herramientas de código abierto tales como: rasterio, numpy, pandas, matplotlib y tensorflow, este trabajo se convierte en una referente para ser replicado y extrapolado por parte de Universidades y Centros de Investigación, en cuanto a la detección de diferentes materiales en imágenes multiespectrales, siendo un aporte a los altos costos de las herramientas propietarias de procesamiento de estas imágenes como ENVI. Así mismo, el uso de estas herramientas facilita la personalización e hibridación de manera sencilla de



diferentes métodos o enfoques, lo cual resulta más complejo de realizarse en herramientas de carácter privativo.

Finalmente, a nivel de las limitaciones de esta investigación cabe mencionar que para el enriquecimiento de la imagen de 4 bandas, es necesario realizar primero la obtención de la capa adicional mediante PCA, por lo cual se requiere contar con un tiempo adicional de pre-procesamiento de la imagen multiespectral, de tal modo que esto debe ser considerado en la adaptación de este enfoque en las aplicaciones de monitorización en tiempo real. A pesar de lo anterior, fue posible apreciar que esta vinculación de las 5 bandas permite que los métodos de EDS y CBS obtengan unos resultados más refinados con respecto a los obtenidos con la imagen de 4 bandas.

#### 4. CONCLUSIONES Y TRABAJO FUTURO

Teniendo en cuenta que aunque las imágenes hiperespectrales presentan como desafío el costo computacional debido a la alta dimensionalidad, en este artículo se propuso como aporte la implementación y evaluación de métodos basados en similitud espectral y modelos RNN en cuanto a la detección de asbesto-cemento en imágenes multiespectrales de 4 y 5 bandas, con el fin de determinar la efectividad de cada uno de estos métodos en la detección de este material mediante el uso de muchas menos bandas de reflectancia. Los resultados obtenidos, permitieron determinar que los métodos de EDS y CBS detectaron zonas de asbesto-cemento en la imagen multiespectral con buena precisión. Estos resultados, permiten que esta investigación y los métodos considerados puedan ser extrapolados en la detección de otros materiales, siendo una alternativa al costo de adquisición y procesamiento de las imágenes hiperespectrales.

En cuanto a las limitaciones de la presente investigación, el enriquecimiento de la imagen de cuatro bandas mediante la incorporación de un componente derivado del análisis de componentes principales (PCA) requiere una etapa adicional de preprocesamiento, lo que implica un incremento en el tiempo computacional que debe ser considerado al adaptar el enfoque a escenarios de procesamiento en tiempo real. No obstante, la inclusión de la quinta banda permitió mejorar la estabilidad de los métodos EDS y CBS en comparación con la configuración de cuatro bandas.

A nivel de eficacia computacional de los métodos evaluados, se obtuvo que con el dataset de 4 bandas, los métodos de distancia espectral SDE y EDS no presentaron traslape en la diferenciación del píxel característico de asbesto-cemento con respecto a los píxeles de muestra de otros materiales, siendo el

método de EDS el que obtuvo la mayor diferencia porcentual entre umbrales de detección con 4.364%. En este mismo sentido, aunque SDE no presenta traslape en los umbrales, su diferencia porcentual entre umbrales es tan solo de 0.067%, lo que lo hace sensible a errores de clasificación, de tal modo que se observa que al desplegarlo sobre la imagen de 4 bandas es el método de distancia espectral que más se equivoca en la clasificación. Ahora bien, en lo que respecta a los resultados con el dataset de 5 bandas, es importante mencionar que los 3 métodos de distancia espectral no presentan traslape en la diferenciación de la firma espectral característica con respecto a los píxeles de muestra de no asbesto, siendo los métodos de CBS y EDS los que presentan un mayor porcentaje de diferenciación entre los umbrales con 2.3% y 3.479% respectivamente. De este modo, la inclusión de una banda adicional contribuye a mejorar la capacidad de detección del método CBS, mientras que se disminuye levemente el umbral de diferenciación de los métodos SDS y EDS. Así mismo, al igual que ocurre con el dataset de 4 bandas el método de SDS obtiene resultados similares, siendo el que más comete errores de clasificación de los 3 métodos de distancia espectral. Por otro lado, en lo que respecta al modelo ANN, aunque en el ajuste y evaluación fue destacado con el conjunto de entrenamiento y prueba para los datasets derivados de las imágenes de 4 y 5 bandas, al desplegar el modelo sobre la imagen completa se presenta una mayor cantidad de errores en la clasificación con respecto a los 3 métodos de distancia espectral, de tal modo que píxeles de vegetación y carreteras son confundidos con píxeles de asbesto-cemento.

A nivel de la eficiencia computacional, los 4 métodos considerados en esta investigación fueron desplegados sobre una región de la imagen de 50x50 píxeles y 5 bandas espectrales en diferentes repeticiones (25, 50, 75 y 100). Como resultado de la evaluación de los métodos en las múltiples repeticiones, se obtuvo que el método de SDS fue el más eficiente en el procesamiento de la región de la imagen con un tiempo promedio de 4.58 milisegundos, mientras que el modelo ANN fue el menos eficiente con un tiempo promedio de procesamiento de 103.88 milisegundos. Ahora bien, a nivel de los métodos con mejor eficacia en la detección, los métodos más eficientes fueron EDS y CBS con tiempos respectivos de procesamiento promedio de 11.18 milisegundos y 24.7 milisegundos, de tal modo que el método de CBS es 2.22 veces más lento que el método de EDS. Los anteriores resultados, permiten concluir que tanto el método EDS, como el CBS pueden ser integrados en sistemas de monitorización en tiempo real.

Este trabajo presentó como contribución adicional el uso de herramientas de código abierto para el pre-procesamiento y detección de asbesto-cemento en

imágenes multiespectrales mediante métodos de similitud espectral y modelos ANN, demostrando que estas librerías y tecnologías pertenecientes al lenguaje Python fueron adecuadas para la experimentación realizada. Así, la librería rasterio fue utilizada para la obtención del arreglo multidimensional que representa la imagen. Del mismo modo, las librerías numpy y scipy fueron empleadas para la implementación, evaluación y despliegue de los 3 métodos de similitud espectral. En este mismo sentido, fue usada la librería tensorflow para la implementación y evaluación de la arquitectura del modelo ANN. Por otra parte, la librería timeit fue usada para la ejecución de múltiples repeticiones de los 4 métodos considerados. Finalmente, las librerías pandas y matplotlib fueron usadas respectivamente para cargar los puntos asociados a los píxeles de muestra y para el despliegue de las gráficas empleadas en esta investigación. Estas herramientas y tecnologías pueden ser extrapoladas en la detección de diferentes materiales en imágenes multiespectrales por parte de centros de investigación y universidades, aprovechando las ventajas de personalización e hibridación de estos métodos en herramientas de código abierto.

Como trabajo futuro derivado de la presente investigación, se pretende en primera instancia evaluar la efectividad de modelos de aprendizaje automático en la detección de asbesto-cemento en imágenes multiespectrales de 4 bandas (NIR) o imágenes de 5 bandas, tales como las usadas en la presente investigación. Del mismo modo, se pretende evaluar la capacidad de detección de los métodos de similitud espectral considerados sobre imágenes satelitales tipo sentinel de 10 bandas, con resoluciones de 10 metros.

### RECONOCIMIENTO

Este artículo se considera un producto derivado del proyecto “Formulación de una estrategia integral para reducir el impacto en la salud pública y ambiental debido a la presencia de asbesto en el territorio del Departamento de Bolívar”, financiado por el Sistema General de Regalías (SGR) de Colombia e identificado con el código BPIN 2020000100366. Este proyecto fue ejecutado por la Universidad de Cartagena, Colombia, y la Fundación Colombia Libre de Asbesto.

### REFERENCIAS

- [1] C. Zhang, «Introduction to Remote Sensing», en *Multi-sensor System Applications in the Everglades Ecosystem*, 2020, pp. 31-60. doi: 10.1201/9780429075872-2.
- [2] J. Awange, «Fundamentals of Remote Sensing», en *Environmental Science and Engineering*, 2019, pp. 115-123. doi: 10.1007/978-3-030-03017-9\_7.
- [3] W. Fu, J. Ma, P. Chen, y F. Chen, «Remote Sensing Satellites for Digital Earth», en *Manual of Digital Earth*, H. Guo, M. F. Goodchild, y A. Annoni, Eds., Singapore: Springer Singapore, 2020, pp. 55-123. doi: 10.1007/978-981-32-9915-3\_3.
- [4] B. Zhang et al., «Remotely sensed big data: evolution in model development for information extraction [point of view]», *Proc. IEEE*, vol. 107, n.o 12, pp. 2294-2301, dic. 2019, doi: 10.1109/jproc.2019.2948454.
- [5] Z. Shun et al., «Research on remote sensing image extraction based on deep learning», *PeerJ Computer Science*, vol. 8, p. e847, ene. 2022, doi: 10.7717/peerj-cs.847.
- [6] A. M. Lechner, G. M. Foody, y D. S. Boyd, «Applications in Remote Sensing to Forest Ecology and Management», *One Earth*, vol. 2, n.o 5, pp. 405-412, may 2020, doi: 10.1016/j.oneear.2020.05.001.
- [7] Z. Wang, Y. Ma, Y. Zhang, y J. Shang, «Review of Remote Sensing Applications in Grassland Monitoring», *Remote Sensing*, vol. 14, n.o 12, p. 2903, jun. 2022, doi: 10.3390/rs14122903.
- [8] M. I. Abdulraheem, W. Zhang, S. Li, A. J. Moshayed, A. A. Farooque, y J. Hu, «Advancement of Remote Sensing for Soil Measurements and Applications: A Comprehensive Review», *Sustainability*, vol. 15, n.o 21, p. 15444, oct. 2023, doi: 10.3390/su152115444.
- [9] P. Wang, X. Ma, y Q. Zhao, «Learning-based classification approach for coded aperture compressive spectral image», en *International Conference on Image, Signal Processing, and Pattern Recognition (ISPP 2023)*, P. Batista y R. Bilas Pachori, Eds., Changsha, China: SPIE, jun. 2023, p. 137. doi: 10.1117/12.2681198.
- [10] A. Bodkin, A. Sheinis, A. Norton, J. Daly, S. Beaven, y J. Weinheimer, «Snapshot hyperspectral imaging: the hyperpixel array camera», en *SPIE Proceedings*, S. S. Shen y P. E. Lewis, Eds., Orlando, Florida, USA: SPIE, may 2009, p. 73340H. doi: 10.1117/12.818929.
- [11] L. Demarchi, A. Kania, W. Cieżkowski, H. Piórkowski, Z. Oświecimska-Piasko, y J. Chormański, «Recursive Feature Elimination and Random Forest Classification of Natura 2000 Grasslands in Lowland River Valleys of Poland Based on Airborne Hyperspectral and LiDAR Data Fusion», *Remote Sensing*, vol. 12, n.o 11, p. 1842, jun. 2020, doi: 10.3390/rs12111842.
- [12] D. Hong et al., «SpectralGPT: Spectral Remote Sensing Foundation Model», *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 46, n.o 8, pp. 5227-5244, ago. 2024, doi: 10.1109/tpami.2024.3362475.

- [13] M. Krówczyńska, E. Raczek, N. Staniszeńska, y E. Wilk, «Asbestos—Cement Roofing Identification Using Remote Sensing and Convolutional Neural Networks (CNNs)», *Remote Sensing*, vol. 12, n.o 3, p. 408, ene. 2020, doi: 10.3390/rs12030408.
- [14] F. Frassy et al., «Mapping Asbestos-Cement Roofing with Hyperspectral Remote Sensing over a Large Mountain Region of the Italian Western Alps», *Sensors*, vol. 14, n.o 9, pp. 15900-15913, ago. 2014, doi: 10.3390/s140915900.
- [15] G. Bonifazi, G. Capobianco, y S. Serranti, «Asbestos containing materials detection and classification by the use of hyperspectral imaging», *Journal of Hazardous Materials*, vol. 344, pp. 981-993, feb. 2018, doi: 10.1016/j.jhazmat.2017.11.056.
- [16] G. Bonifazi, G. Capobianco, y S. Serranti, «Hyperspectral Imaging and Hierarchical PLS-DA Applied to Asbestos Recognition in Construction and Demolition Waste», *Applied Sciences*, vol. 9, n.o 21, p. 4587, oct. 2019, doi: 10.3390/app9214587.
- [17] O. Trotta, G. Bonifazi, G. Capobianco, y S. Serranti, «DETECTION OF ASBESTOS CONTAINING MATERIAL IN POST-EARTHQUAKE BUILDING WASTE THROUGH HYPERSPECTRAL IMAGING AND MICRO-X-RAY FLUORESCENCE», *Detritus*, n.o 21, pp. 27-34, dic. 2022, doi: 10.31025/2611-4135/2022.17233.
- [18] M. Hikuwai, N. Patorniti, A. Vieira, G. Frangioudakis Khatib, y R. Stewart, «Artificial Intelligence for the Detection of Asbestos Cement Roofing: An Investigation of Multi-Spectral Satellite Imagery and High-Resolution Aerial Imagery», *Sustainability*, vol. 15, n.o 5, p. 4276, feb. 2023, doi: 10.3390/su15054276.
- [19] D. Enrique Valdelamar Martínez, M. Saba, y L. K. Torres Gil, «Assessment of asbestos-cement roof distribution and prioritized intervention approaches through hyperspectral imaging», *Heliyon*, vol. 10, n.o 3, p. e25612, feb. 2024, doi: 10.1016/j.heliyon.2024.e25612.
- [20] G. E. Chanchí-Golondrino, M. A. Ospina-Alarcón, y M. Saba, «Proposal of a computational method for asbestos detection in hyperspectral images based on the identification of prominent peaks in the spectral signature», *rev. investig. desarro. innov.*, vol. 15, n.o 1, pp. 119-138, mar. 2025, doi: 10.19053/uptc.20278306.v15.n1.2025.19183.
- [21] B. G. Ram, P. Oduor, C. Igathinathane, K. Howatt, y X. Sun, «A systematic review of hyperspectral imaging in precision agriculture: Analysis of its current state and future prospects», *Computers and Electronics in Agriculture*, vol. 222, p. 109037, jul. 2024, doi: 10.1016/j.compag.2024.109037.
- [22] N. Ghasemi, J. A. Justo, M. Celesti, L. Despoisse, y J. Nieke, «Onboard Processing of Hyperspectral Imagery: Deep Learning Advancements, Methodologies, Challenges, and Emerging Trends», *IEEE J. Sel. Top. Appl. Earth Observations Remote Sensing*, vol. 18, pp. 4780-4790, 2025, doi: 10.1109/jstars.2025.3527898.
- [23] A. C. Toma, S. Panica, D. Zaharie, y D. Petcu, «Computational challenges in processing large hyperspectral images», en *2012 5th Romania Tier 2 Federation Grid, Cloud & High Performance Computing Science (RQLCG)*, oct. 2012, pp. 111-114. Accedido: 12 de julio de 2025. [En línea]. Disponible en: <https://ieeexplore.ieee.org/document/6528260>
- [24] S. Li, W. Song, L. Fang, Y. Chen, P. Ghamisi, y J. A. Benediktsson, «Deep Learning for Hyperspectral Image Classification: An Overview», *IEEE Trans. Geosci. Remote Sensing*, vol. 57, n.o 9, pp. 6690-6709, sep. 2019, doi: 10.1109/tgrs.2019.2907932.
- [25] M. E. Paoletti, J. M. Haut, J. Plaza, y A. Plaza, «Deep learning classifiers for hyperspectral imaging: A review», *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 158, pp. 279-317, dic. 2019, doi: 10.1016/j.isprsjprs.2019.09.006.
- [26] Z. Yu y W. Cui, «LSCA-net: A lightweight spectral convolution attention network for hyperspectral image processing», *Computers and Electronics in Agriculture*, vol. 215, p. 108382, dic. 2023, doi: 10.1016/j.compag.2023.108382.
- [27] U. Ghous, M. S. Sarfraz, M. Ahmad, C. Li, y D. Hong, «EXNet: (2+1)D Extreme Xception Net for Hyperspectral Image Classification», *IEEE J. Sel. Top. Appl. Earth Observations Remote Sensing*, vol. 17, pp. 5159-5172, 2024, doi: 10.1109/jstars.2024.3362936.
- [28] Y.-L. Chang et al., «Consolidated Convolutional Neural Network for Hyperspectral Image Classification», *Remote Sensing*, vol. 14, n.o 7, p. 1571, mar. 2022, doi: 10.3390/rs14071571.
- [29] J. M. Bioucas-Dias et al., «Hyperspectral Unmixing Overview: Geometrical, Statistical, and Sparse Regression-Based Approaches», *IEEE J. Sel. Top. Appl. Earth Observations Remote Sensing*, vol. 5, n.o 2, pp. 354-379, abr. 2012, doi: 10.1109/jstars.2012.2194696.
- [30] X. Huang, P. Wang, S. Zhang, X. Zhao, y Y. Zhang, «Structural health monitoring and material safety with multispectral technique: A review», *Journal of Safety Science and Resilience*, vol. 3, n.o 1, pp. 48-60, mar. 2022, doi: 10.1016/j.jnlssr.2021.09.004.

- [31] L. Wunsch, M. Hubold, R. Nestler, y G. Notni, «Realisation of an Application Specific Multispectral Snapshot-Imaging System Based on Multi-Aperture-Technology and Multispectral Machine Learning Loops», *Sensors*, vol. 24, n.o 24, p. 7984, dic. 2024, doi: 10.3390/s24247984.
- [32] Y. Chen, H. Jiang, C. Li, X. Jia, y P. Ghamisi, «Deep Feature Extraction and Classification of Hyperspectral Images Based on Convolutional Neural Networks», *IEEE Trans. Geosci. Remote Sensing*, vol. 54, n.o 10, pp. 6232-6251, oct. 2016, doi: 10.1109/TGRS.2016.2584107.
- [33] E. Maggiori, Y. Tarabalka, G. Charpiat, y P. Alliez, «Convolutional Neural Networks for Large-Scale Remote-Sensing Image Classification», *IEEE Trans. Geosci. Remote Sensing*, vol. 55, n.o 2, pp. 645-657, feb. 2017, doi: 10.1109/TGRS.2016.2612821.
- [34] F. Melgani y L. Bruzzone, «Classification of hyperspectral remote sensing images with support vector machines», *IEEE Trans. Geosci. Remote Sensing*, vol. 42, n.o 8, pp. 1778-1790, ago. 2004, doi: 10.1109/TGRS.2004.831865.
- [35] R. H. Yuhas, A. F. Goetz, y J. W. Boardman, «Discrimination among semi-arid landscape endmembers using the spectral angle mapper (SAM) algorithm», en *JPL, Summaries of the Third Annual JPL Airborne Geoscience Workshop. Volume 1: AVIRIS Workshop*, 1992.
- [36] N. Audebert, B. Le Saux, y S. Lefèvre, «Beyond RGB: Very high resolution urban remote sensing with multimodal deep networks», *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 140, pp. 20-32, jun. 2018, doi: 10.1016/j.isprsjprs.2017.11.011.
- [37] F. Martínez-Plumed et al., «CRISP-DM Twenty Years Later: From Data Mining Processes to Data Science Trajectories», *IEEE Transactions on Knowledge and Data Engineering*, vol. 33, n.o 8, pp. 3048-3061, 2021, doi: <https://doi.org/10.1109/TKDE.2019.2962680>.
- [38] J. Saltz, «CRISP-DM for Data Science: Strengths, Weaknesses and Potential Next Steps», presentado en 2021 IEEE International Conference on Big Data (Big Data), Orlando, FL, USA, 2021. doi: <https://doi.org/10.1109/BigData52589.2021.9671634>.
- [39] C. Schröer, F. Kruse, y J. Gómez, «A Systematic Literature Review on Applying CRISP-DM Process Model.», *Procedia Computer Science*, vol. 181, pp. 526-534, 2021, doi: <https://doi.org/10.1016/j.procs.2021.01.199>.
- [40] A. M. Shimaoka, R. C. Ferreira, y A. Goldman, «The evolution of CRISP-DM for Data Science: Methods, Processes and Frameworks», *Reviews*, vol. 4, n.o 1, pp. 28-43, oct. 2024, doi: 10.5753/reviews.2024.3757.
- [41] D. Enrique Valdelamar Martínez, M. Saba, y L. K. Torres Gil, «Assessment of asbestos-cement roof distribution and prioritized intervention approaches through hyperspectral imaging», *Heliyon*, vol. 10, n.o 3, feb. 2024, doi: 10.1016/j.heliyon.2024.e25612.