

Método para la detección de asbesto en imágenes hiperespectrales a partir de los componentes aproximados de la transformada wavelet y la similitud diferencial espectral

Method for asbestos detection in hyperspectral images based on the approximate components of the wavelet transform and spectral differential similarity

PhD. Gabriel Elías Chanchí Golondrino¹, PhD. Manuel Saba¹
PhD. Manuel Alejandro Ospina Alarcón¹

¹ Universidad de Cartagena, Facultad de Ingeniería, Cartagena, Bolívar, Colombia.

Correspondencia: gchanchig@unicartagena.edu.co

Recibido: 15 enero 2025. Revisado: 17 mayo 2025. Aceptado: 20 junio 2025. Publicado: 01 julio 2025.

Cómo citar: G. E. Chanchí Golondrino, M. Saba, y M. A. Ospina Alarcón, «Método para la detección de asbesto en imágenes hiperespectrales a partir de los componentes aproximados de la transformada wavelet y la similitud diferencial espectral», RCTA, vol. 2, n.º 46, pp. 68–77, jul. 2025.

Recuperado de <https://ojs.unipamplona.edu.co/index.php/rcta/article/view/3521>

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



Resumen: Considerando que uno de los desafíos en la detección de materiales en el campo de las imágenes hiperespectrales ante la alta dimensionalidad, es la identificación de métodos computacionales más eficientes, en este artículo se propone como contribución un método para la detección de asbesto basado en el uso de los componentes aproximados de la transformada wavelet y la similitud diferencial espectral. Las variantes del método propuesto fueron implementadas mediante el uso de las librerías de código abierto: spectral, Pywavelets, numpy, pandas y matplotlib, obteniendo una efectividad similar en la detección de asbesto con respecto al método de la correlación. Así mismo, a nivel de la eficiencia computacional, se obtuvo que las tres variantes del método resultaron más eficientes que el método de la correlación, siendo el método basado en el primer componente de la transformada el que obtuvo los mejores resultados al ser 13.964% más eficiente. A partir de los resultados obtenidos, las variantes del método propuesto pueden ser consideradas como una alternativa a los métodos convencionales, de tal forma que pueden ser articuladas en sistemas de análisis y monitorización de asbesto y otros materiales a partir del uso de imágenes hiperespectrales. Así mismo, este trabajo demostró la factibilidad del uso de herramientas y librerías de código abierto en la identificación de materiales en imágenes hiperespectrales, por lo que esta investigación puede ser tomada como punto de referencia que centros de investigación y universidades repliquen y adapten estos métodos en investigaciones basadas en sensado remoto.

Palabras clave: Asbesto-cemento, imágenes hiperespectrales, sensado remoto, transformada wavelet.

Abstract: Considering that one of the challenges in material detection within the field of hyperspectral imaging, given its high dimensionality, is the identification of more computationally efficient methods, this article proposes a method for asbestos detection based on the use of the approximate components of the wavelet transform and spectral differential similarity. Variants of the proposed method were implemented using open-source libraries, including Spectral, PyWavelets, NumPy, Pandas, and Matplotlib, achieving similar effectiveness in asbestos detection compared to the correlation-based method. Furthermore, in terms of computational efficiency, it was found that the three variants of the proposed method were more efficient than the correlation-based method, with the method based on the first component of the wavelet transform yielding the best results, being 13.964% more efficient. Based on these results, the variants of the proposed method can be considered as alternatives to conventional methods, allowing them to be integrated into systems for the analysis and monitoring of asbestos and other materials using hyperspectral images. Additionally, this study demonstrated the feasibility of using open-source tools and libraries for material identification in hyperspectral images, making this research a reference point for research centers and universities to replicate and adapt these methods in remote sensing-based investigations.

Keywords: Asbestos-cement, hyperspectral images, remote sensing, wavelet transform.

1. INTRODUCCIÓN

El sensado remoto o teledetección, puede ser definido como una técnica cuyo objetivo es adquirir información de la superficie terrestre usando sensores dispuestos en satélites, aviones y drones, mediante el uso de métodos espectroscópicos, es decir a partir de la interacción de la energía electromagnética con los objetos de la superficie terrestre, permitiendo obtener datos sin contacto físico directo [1]-[3]. La teledetección utiliza diversas regiones del espectro electromagnético, incluidas la luz visible, el infrarrojo y las microondas, con el propósito de registrar la energía o reflectancia emitida por la superficie terrestre [4], [5]. Dentro de las ventajas de la teledetección, se destaca la reducción significativa del tiempo y el costo asociado con los métodos tradicionales de recopilación de datos terrestres, permitiendo la adquisición rápida de datos en grandes áreas, lo que es particularmente beneficioso para la monitorización ambiental y la agricultura [3], [6].

Una de las técnicas más difundidas del sensado remoto son las imágenes hiperespectrales, la cual se basa en la adquisición simultánea de imágenes en cientos de bandas estrechas, lo que permite una caracterización detallada de los materiales observados mediante el uso de sus firmas espectrales únicas [7], [8]. Estas imágenes almacenan los datos en estructuras tridimensionales conocidas como datacubos, los cuales contienen información espacial (x, y) y espectral (λ) o asociado a la reflectancia [9], [10]. De este modo en un

datacubo hiperespectral tiene un espectro completo o firma espectral que representa las propiedades de absorción y dispersión de la luz asociadas al material al que pertenece el píxel [11]. Mientras que las imágenes multiespectrales capturan datos de hasta diez bandas espectrales que son más anchas y no superpuestas, estas bandas son más limitadas en comparación con las imágenes hiperespectrales, las cuales capturan datos de reflectancia en decenas a cientos de bandas espectrales estrechas y contiguas, proporcionando un espectro detallado para cada píxel de la imagen [12], [13].

En lo que respecta a la detección de asbesto mediante imágenes hiperespectrales se han desarrollado diferentes investigaciones. Así en [14], [15] se ha hecho uso de imágenes hiperespectrales en el rango infrarrojo de onda corta (SWIR: 1000-2500 nm) con el fin de detectar y clasificar materiales de asbesto como amosita, crocidolita y crisotilo en matrices de cemento, obteniendo una buena efectividad con técnicas de análisis de componentes principales (PCA) y Modelado Independiente de Analogías de Clase Suave (SIMCA). Del mismo modo, en [16], [17] se ha hecho uso de manera efectiva de modelos de aprendizaje supervisado basados en máquinas de soporte vectorial (SVM) y análisis de regresión de mínimos cuadrados parciales para la identificación de materiales que contienen asbesto en residuos de construcción y demolición, demostrando ser una estrategia prometedora para el control de calidad. De otra parte, en [18] se desarrolló un modelo de red neuronal dinámica para la identificación de techos

de asbesto usando imágenes hiperespectrales en áreas urbanas y rurales de hasta 8000 kilómetros. Así mismo, en [19] se hizo uso de redes neuronales convolucionales sobre un dataset de imágenes hiperespectrales de Polonia, con el fin de identificar techos de fibrocemento, obteniendo una precisión superior al 90%.

A partir de lo anterior es posible observar cómo se han difundido por su eficacia en la detección de asbesto en imágenes hiperespectrales, los modelos basados en aprendizaje automático y redes neuronales. A pesar de lo anterior, dentro de los desafíos de estos modelos en el contexto de las imágenes hiperespectrales se encuentra la capacidad de cómputo requerida para procesar un volumen de datos considerable, derivado de los cientos de bandas espectrales con las que cuentan estas imágenes [8]. En ese mismo sentido, la complejidad de los modelos de aprendizaje automático se incrementa con la dimensionalidad de los datos, lo que puede llevar a problemas de sobreajuste y a la necesidad de técnicas de reducción de dimensionalidad [20], [21]. De este modo, se requiere contar con métodos alternativos y con menos complejidad que demanden menos recursos computacionales y puedan tener una eficacia similar a la obtenida por los métodos más difundidos, como es el caso de los basados en aprendizaje automático y correlación.

En este artículo se propone como contribución un método matemático alternativo para la detección de asbesto-cemento en imágenes hiperespectrales a partir del uso de los niveles de los componentes aproximados de la transformada wavelet de Haar y del método de la similitud diferencial espectral. La transformada wavelet fue usada para obtener una versión resumida tanto de la firma espectral del asbesto-cemento, como de la firma de los diferentes píxeles de la imagen, para luego calcular la similitud espectral entre ambos componentes aproximados y determinar la posible clasificación de un píxel de la imagen (asbesto o no asbesto). La transformada wavelet permite descomponer una señal en componentes de diferentes escalas, de tal modo que el componente de aproximación es responsable de la información global de la señal [22] y es crucial en aplicaciones que requieren una representación multiresolución de la señal [23]. La componente aproximada es obtenida al aplicar un filtro de baja frecuencia a la señal original, lo que resulta en una representación que retiene la información esencial de la señal en una escala más amplia [24]. El proceso de descomposición de la señal en sus diferentes componente es realizado de manera jerárquica,

permitiendo que la señal puede ser analizada en diferentes niveles de resolución [25]. De este modo, en la presente investigación, se hizo uso el primer, segundo y tercer nivel de jerarquía de la componente aproximada, de cara a evaluar la efectividad del método propuesto.

El método propuesto con sus diferentes variantes (diferente niveles de jerarquía de la transformada) fue evaluado con respecto al método de la correlación, el cual es uno de los más difundidos en la detección de materiales en el ámbito de las imágenes hiperespectrales [26]. Cabe mencionar que el método propuesto fue implementado mediante el uso de librerías y tecnologías del dominio del código abierto, tales como spectral, Pywavelets, numpy, pandas y matplotlib, de tal modo que pueda ser extrapolado en el contexto académico y empresarial para el análisis y detección de asbesto y otros materiales en imágenes hiperespectrales. Dados los resultados obtenidos con el método a nivel de eficacia y eficiencia, puede ser integrado en sistemas automatizados para la detección de diferentes tipos de materiales. Finalmente, este método resulta de gran relevancia en el contexto de Colombia, de cara a la detección de asbesto y la priorización de la intervención de zonas urbanas específicas, teniendo en cuenta los impactos del asbesto a la salud a nivel de enfermedades pulmonares como la asbestosis y el mesotelioma [27]-[29].

El resto del artículo está organizado de la siguiente forma: En la sección 2 se presentan las fases metodológicas consideradas para el desarrollo de la presente investigación. En la sección 3 se presentan los resultados obtenidos en esta investigación, lo cual incluye en primera instancia la determinación de los primeros 3 niveles de los componentes aproximados de la transformada wavelet asociada a la firma espectral del asbesto cemento. Así mismo esta sección incluye la implementación y evaluación de los 3 métodos (1 por cada componente) con los píxeles de muestra de asbesto y no asbesto, con el fin de identificar los umbrales mínimos de detección de asbesto por cada componente. Similarmente, usando los umbrales detectados para cada componente, esta sección presenta el despliegue de los 3 métodos sobre la imagen completa para determinar el porcentaje de asbesto obtenido por cada método. Por otra parte, esta sección incluye la evaluación de la efectividad y eficiencia de cada método con respecto al método de la correlación. Finalmente, en la sección 4 se presentan las conclusiones y los trabajos futuros derivados de la presente investigación.

2. METODOLOGÍA

Para el desarrollo de la presente investigación, fueron definidas 5 fases metodológicas a saber: F1. Selección de píxeles de muestra de asbesto y otros materiales, F2. Determinación del píxel característico de asbesto, F3. Implementación y evaluación de las variantes del método con píxeles de asbesto y de otros materiales, F4. Despliegue de las variantes del método sobre la imagen de referencia, F5. Evaluación de la eficacia y eficiencia de las variantes del método con respecto al método de correlación.




Fig. 1. Metodología considerada.
Fuente: elaboración propia.

En la Fase 1 de la metodología fueron seleccionados un conjunto de 75 píxeles de asbesto y 75 píxeles de otros materiales a partir de una imagen hiperspectral de referencia de 725x850 píxeles con 380 bandas de reflectancia por píxel correspondiente a una zona representativa del barrio Manga de la ciudad de Cartagena de Indias. Así, en la Figura 2 es presentada una representación RGB de la imagen hiperspectral, en la cual se han resaltado en color verde los 75 píxeles de asbesto seleccionados y en color azul los 75 píxeles de otros materiales.




Fig. 2. Píxeles seleccionados de asbesto y de otros materiales.
Fuente: elaboración propia.

Cabe mencionar que estos píxeles de muestra fueron seleccionados para identificar los umbrales de detección de cada variante del método propuesto. En la fase 2 de la metodología, fue determinado el píxel característico del asbesto cemento, a partir del promedio banda a banda de reflectancia normalizada de los 75 píxeles de muestra, el cual corresponde a la curva característica que permite diferenciar al asbesto de otros materiales. De este modo, en la Figura 3 se presenta la curva espectral normalizada de los 75 píxeles de asbesto y el píxel característico obtenido a partir de estos píxeles de muestra.




Fig. 3. Firma espectral característica del asbesto-cemento.
Fuente: elaboración propia.

Una vez obtenida la firma espectral característica del asbesto-cemento, en la fase 3 de la metodología se obtuvieron en primera instancia los componentes aproximados correspondientes a los 3 primeros niveles de la transformada wavelet de Haar, los cuales corresponden a una representación resumida del píxel característico, de tal modo que por cada componente de la transformada se obtiene una representación con la mitad de número de bandas del nivel anterior. De este modo, usando cada una de las 3 firmas espectrales resumidas, se realizó la iteración por los 75 píxeles de asbesto y 75 de no asbesto, de tal modo que por cada píxel se obtuvo la transformada wavelet correspondiente al nivel de la firma espectral usada y se determinaron las similitudes entre los componentes aproximados de cada píxel y la firma espectral usada mediante la similitud diferencial espectral, con el fin de detectar para cada firma el porcentaje de similitud mínimo con píxeles asbesto y el porcentaje de similitud máximo con píxeles de otros materiales. Así, para el cálculo de la transformada wavelet del píxel característico, como de cada píxel de muestra, en sus diferentes niveles se hizo uso de una adaptación de la ecuación (1), la cual corresponde al primer nivel del componente aproximado. Se puede apreciar que dado que la transformada de Haar opera a pares consecutivos, el valor de i en la ecuación varía hasta el valor de 190, el cual es la mitad de 380.

$$A_i = \frac{r_{2i-1} + r_{2i}}{\sqrt{2}}, i = 1, \dots, 190 \quad (1)$$

Por otro parte, la para la similitud de los componentes aproximados de la firma espectral y de cada pixel, se hizo uso de la ecuación (2), la cual calcula el porcentaje de similitud espectral entre los componentes [30].

$$sim = 100 - \frac{\sum_{i=1}^n |pix_i - pix_{prom}|}{n} \times 100 \quad (2)$$

Una vez fueron detectados el porcentaje de similitud mínimo con asbesto y el porcentaje de similitud máximo con pixeles de no asbesto para cada uno de los 3 niveles de la transformada wavelet, en la fase 4 de la metodología se procedió con el despliegue de las 3 variantes del método sobre la imagen completa, obteniendo para cada caso el porcentaje de pixeles de asbesto que corresponden a la imagen de referencia.

Finalmente, en la fase 5 los porcentajes obtenidos por cada una de las 3 variantes del método fueron comparados con el porcentaje de asbesto obtenido por el método de la correlación, el cual ha sido difundido en la detección de materiales en imágenes hiperespectrales. Así, mismo, dentro de esta fase se hizo la evaluación de la eficiencia de las 3 variantes del método con respecto al método de la correlación, de tal modo que los cuatro métodos fueron ejecutados un total de 100 veces sobre una región de la imagen de referencia de tamaño 20x20 pixeles con 380 bandas de reflectancia cada uno. De este modo, por cada método se obtuvo el tiempo promedio de procesamiento de la imagen y se realizó un ranking de eficacia, determinando el método con la mejor efectividad y eficiencia en comparación con el método de la correlación.

3. RESULTADOS Y DISCUSIÓN

En primer lugar, a nivel de los resultados, se obtuvieron a partir del pixel característico o promedio de asbesto (ver Figura 3), los componentes aproximados de la transformada wavelet, en sus 3 primeros niveles, los cuales son presentados en la Figura 4, junto con la firma espectral original. Es posible apreciar a partir de la Figura 4, como la firma espectral original tiene un total de 380 bandas de reflectancia, las cuales se reduciendo a la mitad por cada uno de los 3 componentes aproximadas de la transformada wavelet de Haar. De este modo, aunque se va conservando la forma de la firma espectral, el primer componente cuenta con 190 bandas, el segundo

componente tiene 95 bandas y el tercer componente cuenta con 48 bandas.




Fig. 4. Primeros 3 niveles del componente aproximado.

Fuente: elaboración propia.

Ahora bien, tal como se mencionó en la metodología, cada uno de los 3 primeros componentes fue utilizado para evaluar la capacidad de detección de asbesto usando los 75 pixeles de asbesto y los 75 pixeles de no asbesto, de tal modo que para cada uno de los 3 componentes se obtuvo con respecto a la firma espectral resumida correspondiente, el porcentaje de similitud espectral mínimo con pixeles de asbesto y el porcentaje de similitud espectral máximo con pixeles de otros materiales. Así a modo de ejemplo, en la Figura 5 se presentan los umbrales detectados para cada uno de los niveles de los componentes de la transformada wavelet de Haar.




Fig. 5. Umbrales mínimos y máximos por nivel del componente.

Fuente: elaboración propia.

De acuerdo con los resultados presentados en la Figura 5, es posible apreciar como en los 3 diferentes niveles del componente aproximado no se presentan traslapes entre el porcentaje mínimo de similitud con asbesto y el porcentaje máximo de similitud con otros materiales. Así mismo, es posible apreciar como a medida que se incrementa el nivel del componente o se hace más resumida la firma espectral del asbesto, el porcentaje mínimo de detección disminuye y la diferencia entre los dos

umbrales aumenta. De este modo mientras que para el componente del primer nivel la diferencia entre los umbrales es de 0.01, para el tercer nivel la diferencia entre los umbrales es de 0.019.

Así una vez identificados los umbrales para las 3 variantes del método, se procedió con el despliegue de los mismos sobre el total de la imagen de referencia, de tal modo que por cada pixel de la imagen se obtuvo por cada método el respectivo nivel del componte aproximado y se halló la similitud con la firma espectral asociada al nivel, clasificando cada pixel como de asbesto o no asbesto según el umbral descrito en la Figura 5. Así, a modo de ejemplo en la Figura 6, se muestra tanto la aplicación del método para el primer componente de la transformada sobre la imagen de referencia, como el resultado obtenido en la detección, donde en color azul son resaltados los pixeles detectados de asbesto. A partir de lo anterior, es importante mencionar que a medida que aumenta el nivel del componente, aunque los cálculos recursivos se incrementan, existe menos probabilidad de que el método confunda pixeles de asbesto con los de otros materiales.




Fig. 6. Pixeles de asbesto detectados para el primer componente aproximado.

Fuente: elaboración propia.

Del mismo modo como se aplicó el método con el primer componente en la imagen completa, fue realizada la adaptación de este con el segundo y tercer componente, ajustando en cada caso los umbrales de detección respectivos. De esta manera, por cada variante del método se obtuvo un porcentaje de asbesto detectado sobre la imagen completa, el cual fue contrastado con el porcentaje de asbesto detectado por el método de correlación, previa obtención de los umbrales de detección en este método. Así en la Figura 7 es presentada la implementación del método de correlación sobre la imagen completa, tomando como umbral mínimo de detección para la correlación, el porcentaje mínimo de 99.369%.




Fig. 7. Pixeles de asbesto detectados por el método de la correlación.

Fuente: elaboración propia.

Así mismo, en la Figura 8, son presentados los porcentajes de asbesto detectados por cada uno de los métodos considerados en contraste con el método de correlación. Se puede apreciar como los cuatro métodos detectan un porcentaje de asbesto en la imagen cercano al 10%, siendo el método basado en el componente del nivel 1 el que más se aproxima al porcentaje detectado por la correlación, con una diferencia porcentual de 1.072%. A pesar de lo anterior, la mayor diferencia con el método de correlación es tan solo de 1.229% y corresponde al método basado en el componente del nivel 3. De este modo, es posible concluir como las variantes de los 3 métodos a nivel de efectividad, tienen resultados consistentes con respecto al método de correlación y pueden considerarse alternativas viables.




Fig. 8. Porcentaje de asbesto detectado por cada uno de los métodos.

Fuente: elaboración propia.

Ahora bien, con el fin de evaluar la eficiencia de las 3 variantes del método, con respecto al método de la correlación, se realizaron 100 ejecuciones de los 4 métodos sobre una región de la imagen de referencia de 20x20 pixeles, cada uno con 380 bandas de reflectancia. Estas evaluaciones se realizaron a partir del uso de la librería timeit de Python en un entorno convencional en la nube de Google Colab con 12.67GB de memoria RAM de disponibilidad. Así, por cada método se obtuvo el tiempo promedio de procesamiento de la región de la imagen en 100 ejecuciones, obteniendo los resultados que se presentan en la Figura 9.




Fig. 9. Tiempo de procesamiento obtenido por método.
Fuente: elaboración propia.

De acuerdo con los resultados presentados en la Figura 9, es posible apreciar como el tiempo de procesamiento de los métodos es similar entre sí, variando entre los 0.191 ms y los 0.222 ms, de tal modo que los 3 métodos basados en los diferentes niveles del componente aproximado obtienen mejor rendimiento que el método de correlación. Así mismo, se aprecia que el método basado en el primer nivel del componente aproximado, es el que obtiene el mejor tiempo de procesamiento con 0.191 ms. De este modo al relacionar los tiempos de cada método, es posible obtener el porcentaje de eficiencia con respecto al método de la correlación, tal como se presenta en la Figura 10.




Fig. 10. Eficiencia de los métodos con respecto al método de correlación.
Fuente: elaboración propia.

De acuerdo con los resultados de la Figura 10, es posible apreciar como el método basado en el primer componente de la transformada de Wavelet tiene los mejores resultados, con un 13.964% de incremento de eficiencia. Esto se explica en que el cálculo de un mayor número de componentes representa un cálculo recursivo adicional, sin embargo, dados los resultados de eficiencia y eficacia cualquiera de los 3 métodos considerados puede ser considerado como alternativa al método de la correlación.

El presente artículo propuso como contribución un nuevo método para la detección de asbesto en imágenes hiperespectrales basado en el uso de los 3

primeros niveles de los componentes aproximados de la transformada wavelet de Haar, el cual demostró en sus diferentes variantes tener una capacidad similar de detección de asbesto-cemento y un mejor rendimiento computacional, con respecto al método de la correlación, el cual ha sido difundido en la detección de materiales en imágenes hiperespectrales [26]. En este mismo sentido, a partir de los resultados obtenidos a nivel de eficiencia y dada la complejidad que presentan los modelos de aprendizaje automático en el procesamiento de imágenes hiperespectrales de gran volumen [20], [21], el método propuesto representa una alternativa adecuada para ser integrado en sistemas de detección y monitorización de materiales a partir de imágenes hiperespectrales en zonas urbanas. Finalmente, dado el uso para la implementación y evaluación del método de librerías y tecnologías del campo del código abierto, este trabajo muestra la factibilidad del uso de estas tecnologías para la detección de materiales en imágenes hiperespectrales, permitiendo que estos métodos y sus variaciones puedan ser replicados en entornos académicos y empresariales, ante los altos costos de las herramientas propietarias para el procesamiento de estas imágenes.

4. CONCLUSIONES

A partir de la necesidad de métodos más eficientes y con una precisión similar a los métodos convencionales para la detección de materiales y de manera específica asbesto-cemento, en este trabajo se propuso como contribución un nuevo método para la detección de asbesto basado en los niveles de la componente aproximada de wavelet y la similitud diferencial espectral, el cual demostró ser tan efectivo como el método de la correlación y con una mejor eficiencia computacional. De este modo, el método propuesto puede ser considerado como alternativa viable para ser integrado en sistemas de seguimiento y monitorización de materiales en imágenes hiperespectrales.

Al comparar las 3 variantes del método propuesto, basadas en los 3 primeros componentes aproximados de la transformada wavelet, con respecto al método de correlación, se obtuvo como resultado que las diferentes variantes del método detectaron un porcentaje de asbesto similar al detectado por el método de correlación en la imagen hiperespectral de referencia, de tal modo que la mayor diferencia con el método de correlación es tan solo de 1.229% y corresponde al método basado en el tercer componente de la transformada wavelet. En este mismo sentido la variante del método que

obtuvo la menor diferencia fue la basada en el primer componente de la transformada wavelet con una diferencia porcentual de 1.072%. Los resultados obtenidos, permiten concluir que las variantes del método pueden ser consideradas como una alternativa viable al método de correlación en la detección de asbesto y otros materiales.

A nivel de la eficiencia computacional de las variantes del método implementadas, se logró obtener que al realizar 100 ejecuciones de estas y del método de correlación en el procesamiento de una imagen hiperespectral de 20x20 píxeles y 380 bandas de reflectancia, las 3 variantes del método resultaron con una mejor eficiencia que la correlación, siendo entre el 10.360% y 13.964% más eficientes, de tal modo que el método basado en el primer componente obtuvo los mejores resultados. Lo anterior, teniendo en cuenta que el cálculo de un mayor número de componentes implica el uso de cálculos recursivos adicionales. De este modo, las variantes del método pueden ser consideradas como una alternativa viable en el procesamiento de imágenes hiperespectrales de gran volumen, como las obtenidas en el sensado remoto de zonas rurales, donde es necesario el procesamiento eficiente de grandes volúmenes de datos.

A partir de los resultados obtenidos en este trabajo, es posible concluir que el método basado en el primer componente de la transformada wavelet presenta a nivel de la eficacia en la detección resultados similares a los del método de la correlación y a nivel de la eficiencia es 13.964% más eficiente, de tal manera que este método representa la mejor opción a ser considerada en la detección de asbesto-cemento en imágenes hiperespectrales. Cabe mencionar que este método, hace uso de una firma espectral que con respecto a la original, reduce en la mitad el número de bandas, de tal modo que en vez de 380 bandas, usa 190.

Para el desarrollo de la presente investigación, se hizo uso de librerías y tecnologías del dominio del código abierto, las cuales resultaron efectivas en el procesamiento y análisis de imágenes hiperespectrales, de cara a la detección de asbesto cemento. Así, la librería spectral permitió el acceso a los datos de las bandas de reflectancia de la imagen hiperespectral como arreglos tipo numpy; la librería Pywavelets permitió la determinación de los componentes de la transformada wavelet de Haar tanto para la firma espectral del asbesto, como para los píxeles de la imagen; la librería numpy permitió el manejo de los datos de reflectancia de la imagen y la implementación tanto del método de la similitud

diferencial spectral; la librería pandas permitió la carga de las coordenadas correspondientes a los 75 píxeles de muestra de asbesto y a los 75 píxeles de otros materiales; la librería matplotlib posibilitó la generación de las gráficas asociadas a la firma espectral del asbesto original y resumida (derivada de los componentes de la transformada). De este modo, estas librerías pueden ser de gran utilidad a la hora de replicar los experimentos desarrollados o en la detección de otros materiales en imágenes hiperespectrales, teniendo en cuenta los altos costos del software propietario usado para el análisis de estas imágenes.

Como trabajo futuro derivado de esta investigación, se pretende en primera medida, evaluar los métodos propuestos en la detección de diferentes materiales en el contexto ambiental (vegetación, cuerpos de agua, entre otros). Así mismo, se pretende conformar un nuevo dataset de experimentación basado en las firmas espectrales resumidas de una muestra representativa de píxeles de la imagen de referencia a partir del uso de la transformada wavelet. De este modo a partir del uso de este nuevo dataset se busca evaluar la efectividad y eficiencia de métodos basado en aprendizaje automático en la detección de asbesto.

RECONOCIMIENTO

Los autores de la presente investigación agradecen a la Universidad de Cartagena por el apoyo recibido en el desarrollo de la presente investigación.

REFERENCIAS

- [1] J. Awange and J. Kiema, "Fundamentals of Remote Sensing," 2019, pp. 115–123. doi: 10.1007/978-3-030-03017-9_7.
- [2] A. F. Jiménez-López, M. Jiménez-López, and F. R. Jiménez-López, "Multispectral analysis of vegetation for remote sensing applications," *ITECKNE*, vol. 12, no. 2, Nov. 2015, doi: 10.15332/iteckne.v12i2.1242.
- [3] A. A. Misra, "Remote Sensing Fundamentals," in *Atlas of Structural Geological and Geomorphological Interpretation of Remote Sensing Images*, Wiley, 2022, pp. 7–14. doi: 10.1002/9781119813392.ch1.
- [4] C. Nansen and N. Elliott, "Remote Sensing and Reflectance Profiling in Entomology," *Annu. Rev. Entomol.*, vol. 61, no. 1, pp. 139–158, Mar. 2016, doi: 10.1146/annurev-ento-010715-023834.

- [5] R. Naval Gund, V. Jayaraman, and P. Roy, "Remote sensing applications: An overview," *Curr. Sci.*, vol. 93, pp. 1747–1766, 2007.
- [6] B. Verma, M. Porwal, A. K. Jha, R. G. Vyshnavi, A. Rajpoot, and A. K. Nagar, "Enhancing Precision Agriculture and Environmental Monitoring Using Proximal Remote Sensing," *J. Exp. Agric. Int.*, vol. 45, no. 8, pp. 162–176, Jul. 2023, doi: 10.9734/jeai/2023/v45i82168.
- [7] W. M. Castro Silupu, I. J. Yoplac Tafur, and C. A. López Portocarrero, "Predicción del color y contenido de humedad en café cerezo mediante redes neuronales y regresión de mínimos cuadrados parciales," *Cienc. Amaz.*, vol. 5, no. 2, p. 91, Dec. 2015, doi: 10.22386/ca.v5i2.94.
- [8] M. E. Paoletti, J. M. Haut, J. Plaza, and A. Plaza, "Estudio Comparativo de Técnicas de Clasificación de Imágenes Hiperespectrales," *Rev. Iberoam. Automática e Informática Ind.*, vol. 16, no. 2, p. 129, Mar. 2019, doi: 10.4995/riai.2019.11078.
- [9] L. Gao and R. T. Smith, "Optical hyperspectral imaging in microscopy and spectroscopy - a review of data acquisition," *J. Biophotonics*, vol. 8, no. 6, pp. 441–456, Jun. 2015, doi: 10.1002/jbio.201400051.
- [10] B. Park, "Future Trends in Hyperspectral Imaging," *NIR news*, vol. 27, no. 1, pp. 35–38, Feb. 2016, doi: 10.1255/nirn.1583.
- [11] J. Burger and A. Gowen, "Data handling in hyperspectral image analysis," *Chemom. Intell. Lab. Syst.*, vol. 108, no. 1, pp. 13–22, Aug. 2011, doi: 10.1016/j.chemolab.2011.04.001.
- [12] S. Muhammed*, R. D., and V. S., "Hyperspectral and Multispectral Image Fusion Techniques," *Int. J. Recent Technol. Eng.*, vol. 8, no. 5, pp. 467–471, Jan. 2020, doi: 10.35940/ijrte.E4904.018520.
- [13] H. González-Núñez and R. de la Fuente, "Offner imaging spectrometers," *Opt. Pura y Apl.*, vol. 50, no. 1, pp. 37–47, Mar. 2017, doi: 10.7149/OPA.50.1.49506.
- [14] G. Bonifazi, G. Capobianco, and S. Serranti, "Asbestos containing materials detection and classification by the use of hyperspectral imaging," *J. Hazard. Mater.*, vol. 344, pp. 981–993, Feb. 2018, doi: 10.1016/j.jhazmat.2017.11.056.
- [15] G. Bonifazi, G. Capobianco, and S. Serranti, "Hyperspectral imaging applied to the identification and classification of asbestos fibers," in *2015 IEEE SENSORS*, IEEE, Nov. 2015, pp. 1–4. doi: 10.1109/ICSENS.2015.7370458.
- [16] G. Bonifazi, G. Capobianco, S. Serranti, S. Malinconico, and F. Paglietti, "ASBESTOS DETECTION IN CONSTRUCTION AND DEMOLITION WASTE ADOPTING DIFFERENT CLASSIFICATION APPROACHES BASED ON SHORT WAVE INFRARED HYPERSPECTRAL IMAGING," *Detritus*, no. 20, pp. 90–99, Aug. 2022, doi: 10.31025/2611-4135/2022.15211.
- [17] G. Bonifazi, G. Capobianco, and S. Serranti, "Hyperspectral Imaging and Hierarchical PLS-DA Applied to Asbestos Recognition in Construction and Demolition Waste," *Appl. Sci.*, vol. 9, no. 21, p. 4587, Oct. 2019, doi: 10.3390/app9214587.
- [18] D. Gubiani *et al.*, "A dynamic neural network model for the identification of asbestos roofings in hyperspectral images covering a large regional area," *Comput. Civ. Infrastruct. Eng.*, Nov. 2024, doi: 10.1111/mice.13376.
- [19] M. Krówczyńska and E. Wilk, "Identification of asbestos-cement roofing with the use of remote sensing data in the capital city of Poland," *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. XLVIII-3-2, pp. 273–278, Nov. 2024, doi: 10.5194/isprs-archives-XLVIII-3-2024-273-2024.
- [20] Y. Chen, H. Jiang, C. Li, X. Jia, and P. Ghamisi, "Deep Feature Extraction and Classification of Hyperspectral Images Based on Convolutional Neural Networks," *IEEE Trans. Geosci. Remote Sens.*, vol. 54, no. 10, pp. 6232–6251, Oct. 2016, doi: 10.1109/TGRS.2016.2584107.
- [21] J. Torres Tello, "Aprendizaje profundo para predicciones que usan imágenes multiespectrales en agricultura," *ConcienciaDigital*, vol. 6, no. 4.1, pp. 75–87, Oct. 2023, doi: 10.33262/concienciadigital.v6i4.1.2734.
- [22] M. Unser and T. Blu, "Wavelet theory demystified," *IEEE Trans. Signal Process.*, vol. 51, no. 2, pp. 470–483, Feb. 2003, doi: 10.1109/TSP.2002.807000.
- [23] G. C.-H. Chuang and C.-C. J. Kuo, "Wavelet descriptor of planar curves: theory and applications," *IEEE Trans. Image Process.*, vol. 5, no. 1, pp. 56–70, Jan. 1996, doi: 10.1109/83.481671.
- [24] Y. Tounsi, A. Ghlaifan, M. Kumar, F.

- Mendoza-Santoyo, O. Matoba, and A. Nassim, "Fringe Pattern Analysis in Wavelet Domain," in *Holographic Materials and Applications*, IntechOpen, 2019. doi: 10.5772/intechopen.87943.
- [25] R. Ohura and T. Minamoto, "A blind digital image watermarking method based on the dyadic wavelet packet transform and fast interval arithmetic techniques," *Int. J. Wavelets, Multiresolution Inf. Process.*, vol. 13, no. 05, p. 1550040, Sep. 2015, doi: 10.1142/S021969131550040X.
- [26] G. E. Chanchí Golondrino, M. A. Ospina Alarcón, and M. Saba, "Vegetation Identification in Hyperspectral Images Using Distance/Correlation Metrics," *Atmosphere (Basel)*, vol. 14, no. 7, p. 1148, Jul. 2023, doi: 10.3390/atmos14071148.
- [27] M. Kottek and M. L. Yuen, "Public health risks from asbestos cement roofing," *Am. J. Ind. Med.*, vol. 65, no. 3, pp. 157–161, Mar. 2022, doi: 10.1002/ajim.23321.
- [28] M. Krówczyńska and E. Wilk, "Environmental and Occupational Exposure to Asbestos as a Result of Consumption and Use in Poland," *Int. J. Environ. Res. Public Health*, vol. 16, no. 14, p. 2611, Jul. 2019, doi: 10.3390/ijerph16142611.
- [29] C. A. Saito *et al.*, "Sex-Specific Mortality from Asbestos-Related Diseases, Lung and Ovarian Cancer in Municipalities with High Asbestos Consumption, Brazil, 2000–2017," *Int. J. Environ. Res. Public Health*, vol. 19, no. 6, p. 3656, Mar. 2022, doi: 10.3390/ijerph19063656.
- [30] G. Chanchí-Golondrino, M. Ospina-Alarcón, and M. Saba, "Propuesta de un método computacional para la detección de asbesto en imágenes hiperespectrales a partir de la similitud diferencial espectral," *Rev. Colomb. Tecnol. Av.*, vol. 1, no. 45, pp. 195–203, 2025.