

Propuesta de un método computacional para la detección de asbesto en imágenes hiperespectrales a partir de la similitud diferencial espectral

Proposal of a method for asbestos detection in hyperspectral images based on spectral differential similarity

PhD. Gabriel Elías Chanchí Golondrino ¹, PhD. Manuel Saba ¹
PhD. Manuel Alejandro Ospina Alarcón ¹

¹ Universidad de Cartagena, Facultad de Ingeniería, Programa de Ingeniería de Sistemas, Cartagena de Indias, Bolívar, Colombia.

Correspondencia: gchanchig@unicartagena.edu.co

Recibido: 01 julio 2024. Aceptado: 16 noviembre 2024. Publicado: 01 enero 2025.

Cómo citar: G. E. Chanchí Golondrino, M. Saba, y M. A. Ospina Alarcón, «Propuesta de un método computacional para la detección de asbesto en imágenes hiperespectrales a partir de la similitud diferencial espectral», RCTA, vol. 1, n.º 45, pp. 195–203, ene. 2025.
Recuperado de <https://ojs.unipamplona.edu.co/index.php/rcta/article/view/3279>

Derechos de autor 2025 Revista Colombiana de Tecnologías de Avanzada (RCTA).
Esta obra está bajo una licencia internacional [Creative Commons Atribución-NoComercial 4.0](https://creativecommons.org/licenses/by-nc/4.0/).



Resumen: Teniendo en cuenta que uno de los desafíos de las imágenes hiperespectrales es la identificación de métodos que permitan la detección de materiales de manera eficaz y eficiente, en este artículo se propuso un nuevo método para la detección de asbesto en imágenes hiperespectrales basado en la similitud diferencial espectral, a través del cual es posible determinar que tan cercana es la firma espectral de un pixel determinado con respecto a la firma espectral del asbesto. El método propuesto fue implementado mediante el uso de librerías del dominio del código abierto tales como: spectral, numpy, pandas y matplotlib, obteniendo que con respecto al método de correlación fue detectado un 0.813% menos pixeles de vegetación. Así mismo, se obtuvo a nivel de la eficiencia computacional que el método propuesto resultó 4.27 veces más rápido que el método de correlación. Los resultados obtenidos permiten concluir que el método propuesto presenta una adecuada eficacia y una excelente eficiencia, lo cual permite que pueda ser considerado para ser integrado en herramientas para el procesamiento y análisis de imágenes hiperespectrales en el dominio académico y empresarial.

Palabras clave: Asbesto, correlación, imagen hiperespectral, firma espectral, sentido remoto.

Abstract: Considering that one of the challenges of hyperspectral imaging is identifying methods that enable the effective and efficient detection of materials, this article proposes a new method for detecting asbestos in hyperspectral images based on spectral differential similarity. This method determines how closely the spectral signature of a given pixel matches the spectral signature of asbestos. The proposed method was implemented using open-source libraries such as spectral, numpy, pandas, and matplotlib. Compared to the correlation method, it detected 0.813% fewer vegetation pixels. In terms of computational efficiency, the proposed method was 4.27 times faster than the correlation method. The

results indicate that the proposed method demonstrates adequate efficacy and excellent efficiency, making it a strong candidate for integration into tools for processing and analyzing hyperspectral images in academic and industrial domains.

Keywords: Asbestos, correlation, hyperspectral imaging, spectral signature, remote sensing.

1. INTRODUCCIÓN

Las imágenes hiperespectrales (HSI) desempeñan un papel fundamental en el sensado remoto o teledetección, al proporcionar información espectral detallada que permite la identificación y el análisis de diferentes tipos de materiales, al detectar las ondas electromagnéticas reflejadas por los objetos [1]. En este sentido, las HSI capturan datos en una amplia gama de longitudes de onda, desde la ultravioleta hasta la infrarroja, lo que permite un análisis detallado de los materiales y sus propiedades al combinar una alta resolución espectral con una precisión espacial, siendo esta última de gran utilidad en aplicaciones como la agricultura de precisión, donde una observación detallada optimiza los procesos agrícolas [2]. Es así como en los sistemas de imágenes hiperespectrales se conforman los denominados datacubos, los cuales recopilan datos de cientos de bandas espectrales estrechas por cada pixel de la imagen [3].

Son diferentes los campos de aplicación en los que se ha hecho uso de las HSI, de tal modo que en el campo de la agricultura de precisión han sido usadas de manera amplia para la clasificación de cultivos, la detección de enfermedades, la monitorización de las condiciones de los cultivos, tales como la madurez y el estado de los nutrientes [4], [5]. Del mismo modo, en el contexto ambiental las HSI son usadas para la categorización e identificación de la composición de los distintos tipos de elementos que cubren la superficie terrestre, tales como vegetación, agua, suelo y áreas urbanas, posibilitando la gestión de los recursos naturales y el monitoreo de los cambios ambientales [4], [6]–[8]. En este mismo sentido, en el campo de la geología las HSI permiten evaluar e identificar la composición, morfología y estructura de los materiales, siendo una herramienta clave para la exploración y el monitoreo en las ciencias de la tierra [9]. Del mismo modo, las HSI han permitido la identificación y el mapeo con precisión de la distribución de minerales en muestras geológicas, como rocas carbonatadas y núcleos de perforación, mediante el análisis de sus firmas espectrales [10]–[12]. Por su parte en el ámbito militar, las HSI han sido usadas para la

detección y reconocimiento de objetivos de baja firma, es decir aquellos que son difíciles de identificar por sus características de camuflaje o baja emisión, proporcionando una ventaja significativa en aplicaciones tácticas al permitir la localización precisa de objetivos discretos, la detección de objetivos a nivel de subpíxeles, la distinción de características ocultas y camuflajes, la identificación de agentes químicos y la detección de tierra removida sobre objetos enterrados [13]–[15]. Del mismo modo, en el ámbito de la salud pública, el uso de HSI ha sido fundamental tanto para la identificación de asbesto en residuos de construcción y demolición a partir del rango infrarrojo de onda corta (SWIR: 1000–2500 nm), como para la detección de asbesto en techos en zonas urbanas, lo cual es crucial dado que el asbesto representa un serio riesgo para la salud al estar relacionado con enfermedades respiratorias graves, convirtiendo su detección y control en una prioridad para la salud pública [16]–[18]. En este mismo sentido, cabe resaltar que el uso de imágenes hiperespectrales en la detección de asbesto resulta una alternativa más eficiente y económica con respecto a los métodos tradicionales de identificación de asbesto basados en ensayos de laboratorio [19].

A nivel de los desafíos del campo de HSI, es importante destacar que el gran volumen de datos que generan por su alta dimensionalidad requiere importantes capacidades de almacenamiento y procesamiento, por lo que se suelen usar técnicas basadas en reducción de dimensionalidad para gestionar su complejidad [6], [7], [20], [21]. De este modo, aunque existen técnicas que son eficaces y ampliamente difundidas para la detección de materiales en imágenes hiperespectrales como son las técnicas de aprendizaje supervisado, se hace necesario en este contexto contar con soluciones escalables como la formación distribuida en la nube, para gestionar los datos de una forma más eficiente [22]. En este mismo sentido, la naturaleza de la alta dimensionalidad de los datos hiperespectrales hace necesario el uso de técnicas de procesamiento avanzadas que permitan gestionar de manera efectiva la gran cantidad de datos [23], [24]. Como alternativa al desafío de la alta dimensionalidad han

sido propuestos diferentes enfoques tales como la selección de características, el uso de métodos de ganancia de información, buscando preservar la información relevante y reducir la dimensionalidad [25], [26].

De acuerdo con lo anterior y teniendo en cuenta el desafío de la dimensionalidad y la eficiencia en el procesamiento de imágenes hiperespectrales, en este artículo se propone como aporte un nuevo método computacional para la detección de asbesto en imágenes hiperespectrales, el cual está basado en la similitud de un píxel de la imagen hiperespectral con respecto a la firma espectral del asbesto a partir de la diferencia espectral entre las curvas de reflectancia normalizada. El método propuesto fue implementado a través del uso de librerías de código abierto tales como spectral, numpy, pandas, matplotlib y scipy. La evaluación del método propuesto fue realizada sobre una imagen hiperespectral de referencia del barrio Manga de la ciudad de Cartagena, de tal modo que fue comparada la efectividad en la detección y eficiencia computacional del mismo con respecto al método de correlación, el cual ha sido difundido ampliamente en la literatura para la detección de diferentes materiales en imágenes hiperespectrales [27], [28]. Cabe resaltar que este trabajo presenta un aporte relevante en cuanto a la difusión de métodos de detección de asbesto a nivel urbano, dado que la exposición a este material está relacionado problemas de salud graves, como el cáncer de pulmón y el mesotelioma, por lo cual es vital importancia para la salud pública [29]. De este modo, la difusión y aprovechamiento de estas tecnologías ayuda a las autoridades gubernamentales a planificar y priorizar las estrategias de intervención, optimizando la asignación de recursos para la eliminación del asbesto [16], [30]. Así mismo a través de los resultados obtenidos y considerando los desafíos de dimensionalidad en el campo de las imágenes hiperespectrales, se busca ampliar el abanico de opciones eficientes para la detección en este ámbito, de manera que el método pueda aplicarse tanto a nivel académico como empresarial en la identificación de distintos tipos de materiales.

El resto del artículo está organizado de la siguiente forma: en la sección 2 se presentan las fases metodológicas empleadas para el desarrollo de la presente investigación. En la sección 3 se presentan los resultados obtenidos en este trabajo, lo cual incluye la caracterización de la firma espectral del asbesto a partir de la imagen de referencia, la determinación de los umbrales de detección de

asbesto, la implementación del método computacional y finalmente la evaluación de la eficiencia y eficacia del método con respecto al método de correlación. Finalmente, en la sección 4 son presentadas las conclusiones y los trabajos futuros derivados de la presente investigación.

2. METODOLOGÍA

Para el desarrollo de la presente investigación se definieron cuatro fases metodológicas a saber: F1. Selección de píxeles de muestra y obtención de píxel característico, F2. Implementación y determinación de los umbrales de referencia del método, F3. Despliegue del método sobre la imagen de referencia, F4. Evaluación comparativa del método propuesto.

En la fase 1 de la metodología se seleccionó en primera instancia una imagen hiperespectral de referencia del barrio Manga de la ciudad de Cartagena de Indias, la cual tiene como dimensiones 850 píxeles de ancho, 725 píxeles de largo y un total de 380 bandas espectrales. Posteriormente, a partir de la imagen de referencia se realizó el muestreo por inspección visual de 75 píxeles correspondientes a asbesto y 75 píxeles correspondientes a otros materiales (vegetación, agua, techos de metal, carreteras, etc). Estos píxeles se usarán posteriormente para la determinación de los umbrales de referencia en los que el método puede detectar el asbesto.

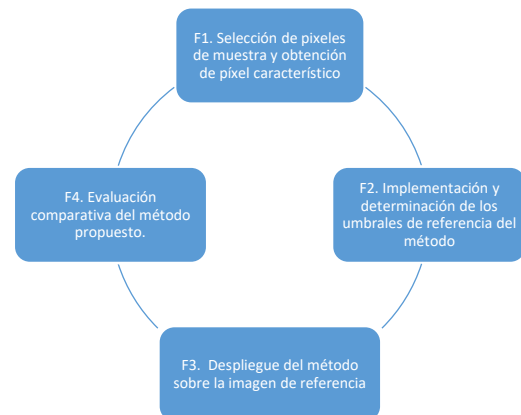


Fig. 1. Metodología considerada para el desarrollo de la investigación.

Fuente: elaboración propia.

Lo mencionado anteriormente, es presentado en la Fig. 2, donde se muestran en color azul los píxeles seleccionados de asbesto y en color rojo los píxeles de otros materiales.




Fig. 2. Pixeles de muestra seleccionados.
Fuente: elaboración propia.

A partir de los pixeles de asbesto seleccionados, se realizó la obtención del píxel promedio, el cual recoge en sus 380 bandas el promedio de reflectancia normalizada de los pixeles de asbesto en sus bandas (ver Figura 3). Este píxel es de gran utilidad, dado que será usado para operar y correlacionar posteriormente con los diferentes tipos de pixeles con el fin de determinar qué tan similares son los pixeles de la imagen al píxel característico del asbesto.

Dentro de la fase 2 de la metodología se realizó la implementación del método de la similitud diferencial espectral haciendo uso de las ventajas provistas por la librería numpy de Python. Este método se implementó a partir de la ecuación (1), la cual a partir de la resta del píxel característico con un píxel determinado de la imagen obtiene el porcentaje de similitud de los dos pixeles.

$$porc_sim = 100 - \frac{\sum_{i=1}^n [pix_i - pix_prom]}{n} \times 100 \quad (1)$$

En la ecuación (1), $\sum_{i=1}^n [pix_i - pix_prom]$ representa la sumatoria de las diferencias absolutas entre un píxel i determinado y el píxel característico o píxel promedio a nivel de las n bandas que componen la imagen hiperespectral, siendo en este caso $n = 380$. De este modo, cuanto más similar sea el píxel i al píxel promedio, la sumatoria tiende a ser 0 y el porcentaje de similitud se acerca a 0. Del mismo modo, dado que la imagen tiene valores de reflectancia normalizada, en el peor de los casos la diferencia banda a banda será de 1 y la sumatoria total de 380, de tal modo que la similitud tenderá a 0. Una vez se ha implementado el método propuesto mediante las librerías de

Python, se procedió a evaluar su efectividad con los 75 pixeles de asbesto y con los 75 pixeles de no asbesto, de tal modo que en ambos casos se determinaron los porcentajes mínimos y máximos de similitud obtenidos mediante la ecuación (1). De este modo, se determinó como umbral de detección, el porcentaje mínimo de similitud con pixeles de asbesto, siempre y cuando dicho valor no se traslape con el valor de similitud máximo obtenido con pixeles de no asbesto.

De otra parte, en la fase 3 de la metodología se procedió a replicar el método sobre todos los pixeles de la imagen, haciendo uso del umbral determinado en la fase 2 y pintando de otro color los pixeles en donde se detecta presencia de asbesto. Cabe mencionar que cada píxel de asbesto detectado es contado, con el fin de determinar el porcentaje de pixeles de asbesto presentes en la imagen de referencia usada. Cabe mencionar que las operaciones de similitud son realizadas sobre la representación normalizada de la imagen, teniendo en cuenta que la ecuación (1) está orientada a valores de reflectancia normalizada. El porcentaje de pixeles de asbesto determinados para la imagen de referencia, es comparado a su vez con el porcentaje de pixeles obtenidos por el método de correlación, con el fin de evaluar la efectividad del método.

Finalmente, en la fase 4 de la metodología se realiza la comparación de eficiencia entre el método de diferencia espectral y el método de correlación, ejecutando dichos métodos sobre una región cuadrada de la imagen de $50 \times 50 \times 380$ pixeles un número determinado de repeticiones (20,40,60,80 y 100 veces), con el fin de obtener el tiempo promedio de una ejecución empleado por los métodos y determinar cuál de los dos presenta una mayor eficiencia computacional.

3. RESULTADOS

Una vez seleccionados los 75 pixeles de muestra de asbesto y los 75 pixeles de otros materiales, tal como se presentó en la metodología, se procedió en primera instancia con la obtención del píxel característico o firma espectral característica de los 75 pixeles de asbesto, realizando para lo anterior el promedio de los valores de reflectancia normalizada de las 380 bandas, lo cual arrojó como resultado la firma espectral característico del asbesto presentada en la Fig. 3.




Fig. 3. Pixel característico obtenido para el asbesto.
 Fuente: elaboración propia.

A partir del pixel característico obtenido, se procedió con la implementación en Python del método de la similitud diferencial espectral y con la evaluación de este método con los pixeles de muestra de asbesto y de otros materiales. Así en la Fig. 4 se presentan de izquierda a derecha la implementación del método mencionado con los 75 pixeles de muestra de asbesto y con los pixeles de no asbesto, de cara a obtener los umbrales que pueden ser usados para la detección de asbesto en la imagen hiperespectral completa de referencia.

```

l_porc_diff=[]
for pix in l_pix_asb:
    diff=np.abs(pix-pix_prom)
    porc=100-(np.sum(diff)/380)*100
    l_porc_diff.append(porc)
arr_porc_diff=np.asarray(l_porc_diff)
print("Avg:",arr_porc_diff.mean())
print("Max:",arr_porc_diff.max())
print("Min: ",arr_porc_diff.min())

l_porc_diff=[]
for pix in l_pix_no_asb:
    diff=np.abs(pix-pix_prom)
    porc=100-(np.sum(diff)/380)*100
    l_porc_diff.append(porc)
arr_porc_diff=np.asarray(l_porc_diff)
print("Avg:",arr_porc_diff.mean())
print("Max:",arr_porc_diff.max())
print("Min:",arr_porc_diff.min())
    
```

Avg: 99.3849054354952 Avg: 91.12311636570678
 Max: 99.8380234366969 Max: 96.77609293084396
 Min: 97.25883508983411 Min: 86.39467138993112

Fig. 4. Evaluación del método con pixeles de asbesto y no asbesto. Fuente: elaboración propia.

A partir de la ejecución de los scripts presentados en la Fig. 4 se obtuvieron los porcentajes de similitud diferencial espectral mínima, máxima y promedio, tal como se presenta en la Fig. 5. Así, se observa que entre el porcentaje de similitud diferencial mínima con pixeles de asbesto (97.259%) y el porcentaje de similitud diferencial máxima con pixeles de no asbesto (96.776%), no se presenta traslape, siendo la diferencia porcentual entre estos dos valores de 0.483%. De este modo, el umbral mínimo de detección de pixeles de asbesto que puede ser considerado para la imagen completa es de 97.259%.

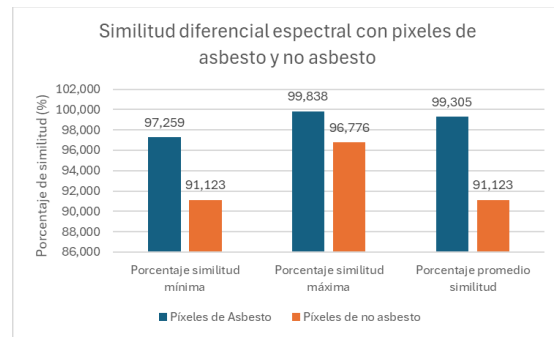


Fig. 5. Porcentajes de diferencia espectral obtenida con pixeles de asbesto y no asbesto. Fuente: elaboración propia.

Del mismo modo, cabe mencionar que al realizar la implementación del método de correlación sobre los mismos 75 pixeles de muestra de asbesto y otros materiales, se obtienen los resultados presentados en la Fig. 6.

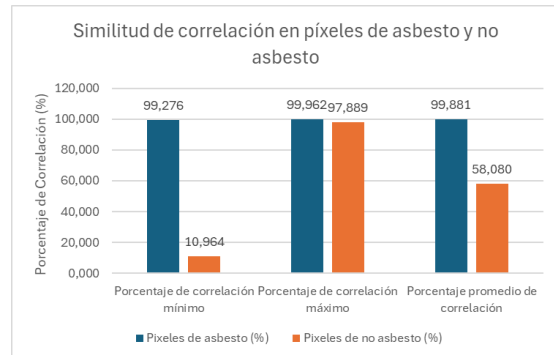


Fig. 6. Porcentajes de correlación obtenidos con pixeles de asbesto y no asbesto. Fuente: elaboración propia.

Es posible observar a partir de la Fig. 6 como en el caso del método de la correlación, la diferencia de similitud entre el porcentaje mínimo de correlación con pixeles de asbesto y el porcentaje máximo de correlación con píxeles de no asbesto es de 1.387%, siendo esta diferencia 2.87 veces mayor que la

diferencia obtenida en el método de similitud diferencial espectral (0.483%). A pesar de lo anterior, en ambos casos los métodos no presentan traslape en la identificación de píxeles de asbesto y no asbesto y el método de diferencia espectral puede ser usado para la detección de este material.

Una vez identificados los umbrales para el método de la similitud diferencial espectral, se procedió con la aplicación tanto de este método, como del método de correlación sobre la imagen de referencia completa, con el fin de evaluar la efectividad de estos en la detección del porcentaje de la imagen que corresponde a asbesto. Así, en la Fig. 7 se presentan los resultados de la implementación de estos métodos sobre la imagen de referencia, de tal modo que en color azul es posible apreciar los píxeles de asbesto detectados por los dos métodos. Cabe resaltar que en ambos métodos se hace uso de la firma espectral o pixel promedio de asbesto para ser operado con los demás píxeles de la imagen.

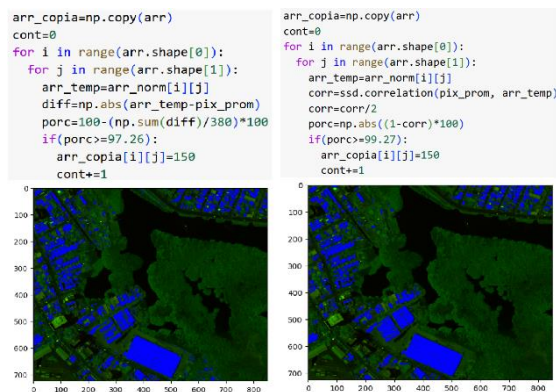


Fig. 7. Detección de asbesto sobre la imagen hiperespectral de referencia mediante los métodos de similitud diferencial y correlación.

Fuente: elaboración propia.

A partir del barrido realizado sobre la imagen completa por parte de los dos métodos implementados, fue obtenido el porcentaje de la imagen que contiene píxeles de asbesto de acuerdo con el conteo realizado por ambos métodos, tal como se presenta en la Fig. 8. Así, tal como se presenta en la Fig. 8, el método de similitud diferencial espectral determinó un porcentaje de píxeles de asbesto del 10.623%, mientras que el método de correlación obtuvo un porcentaje de píxeles de asbesto de 9.81%, con una diferencia porcentual de 0.813%.

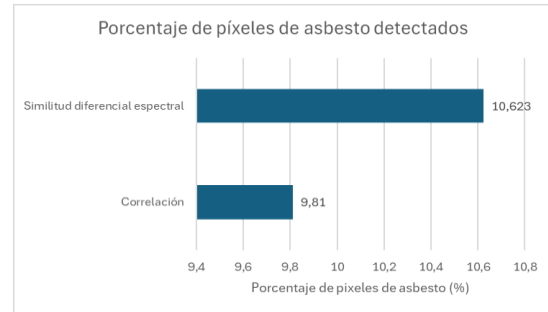


Fig. 8. Porcentaje de píxeles de asbesto detectados.
Fuente: elaboración propia.

Lo resultados anteriores, pueden ser explicados en el hecho de que el método de correlación presenta una mayor diferencia entre el valor porcentual mínimo con píxeles de asbesto y el valor porcentual máximo con píxeles de no asbesto, por lo cual presenta una menor tendencia a confundirse en la distinción de los píxeles de asbesto con respecto a otros píxeles, sin embargo, los dos métodos presentan valores porcentuales de asbesto detectados muy cercanos, por lo cual el método de similitud diferencial espectral puede ser considerado como adecuado para ser usado en la detección de asbesto en imágenes hiperespectrales, dado su bajo margen de error con respecto al método de la correlación.

Una vez fue comparada la eficacia del método de similitud diferencial espectral con respecto al método de correlación, se procedió también a comparar la eficiencia computacional de estos dos métodos. Para lo anterior, se seleccionó una región de 100x100 píxeles cada uno de 380 bandas, sobre la cual se realizaron mediante los dos métodos, 20,40,60,80 y 100 repeticiones, de cara a obtener el tiempo promedio empleado por uno de estos en procesar la región seleccionada y determinar la eficiencia de un método respecto al otro. Se decidió trabajar con una porción de la imagen de referencia, dado que la realización de múltiples ejecuciones sobre la imagen demanda tiempo y recursos considerables. Así, en la Tabla 1 se presentan los resultados obtenidos a nivel de tiempo promedio de ejecución por los dos métodos para las diferentes repeticiones realizadas.

Tabla 1: Tiempo promedio de ejecución por repeticiones

Repeticiones	Tiempo promedio de ejecución – correlación (seg)	Tiempo promedio de ejecución – similitud diferencial (seg)
20	0.542	0.124
40	0.562	0.114
60	0.543	0.136
80	0.540	0.137
100	0.537	0.127
Prom	0.545	0.128

Fuente: elaboración propia

De acuerdo con los resultados presentados en la Tabla 1, es posible apreciar que para los diferentes grupos de repeticiones, el método de correlación presenta un tiempo promedio de ejecución alrededor de 0.545 seg, mientras que el método de la similitud diferencial tiene un promedio de ejecución alrededor de 0.128 seg, de tal modo que el método de la similitud diferencial es 4.27 veces más rápido que el método de correlación. Lo anterior, puede apreciarse en la gráfica presentada en la Fig. 9, donde se muestra que para las diferentes ejecuciones el tiempo empleado por el método de correlación es 4 veces mayor.

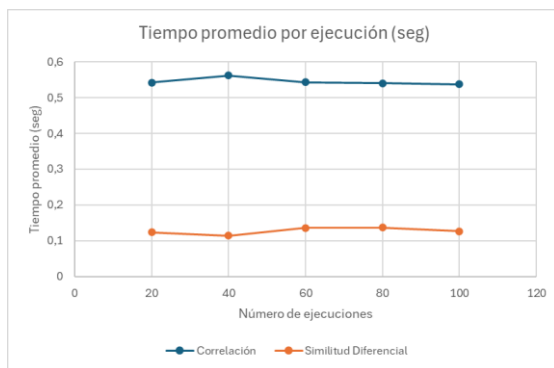


Fig. 9. Tiempo promedio por ejecución en los dos métodos.
Fuente: elaboración propia.

A partir de lo anterior, es posible señalar que el método de similitud diferencial demuestra ser significativamente más eficiente que el método de correlación, una ventaja crucial dadas las grandes dimensiones de los datacubos hiperespectrales generados en el análisis de áreas urbanas. Este método no solo mantiene una eficacia comparable al de correlación, sino que también es 4.27 veces más rápido, convirtiéndolo en una alternativa ideal para su integración en sistemas de análisis de imágenes hiperespectrales. De este modo, su combinación de alta precisión y velocidad optimiza los procesos de análisis y permite un manejo más ágil y efectivo de los grandes volúmenes de datos que estos estudios requieren.

3. CONCLUSIONES Y TRABAJO FUTURO

Teniendo en cuenta que uno de los desafíos en el procesamiento de imágenes hiperespectrales es la identificación de métodos que procesen de manera eficiente el datacubo de datos que representa la imagen y detecten de manera eficaz materiales, en este artículo se propone como contribución un nuevo método para la identificación de la similitud diferencial espectral entre píxeles de asbesto y otros materiales. Este método pretende servir de

alternativa para ser incluido en estudios y herramientas de análisis de imágenes hiperespectrales en el contexto académico o empresarial teniendo en cuenta los resultados obtenidos a nivel de eficacia y eficiencia.

Al comparar la efectividad del método de similitud diferencial espectral con respecto al método de la correlación se observa que el método propuesto logró determinar un porcentaje cercano de píxeles de asbesto, con una diferencia de 0.81% en el porcentaje de píxeles identificados. Lo anterior teniendo en cuenta que la diferencia entre el porcentaje de similitud mínima con píxeles de asbesto y el porcentaje de similitud máxima con píxeles de no asbesto (0.483%) es menor que la diferencia obtenida en el método de la correlación (1.387%). Así, aunque el método de correlación tiene un umbral de detección levemente mayor, la diferencia de píxeles detectados es inferior al 1% por lo que la efectividad del método propuesto puede considerarse adecuada.

Al comparar la eficiencia computacional del método propuesto con el método basado en correlación, se concluyó que el método de la similitud diferencial espectral es 4.27 veces más rápido en las diferentes repeticiones realizadas sobre una región de la imagen hiperespectral de referencia. Esta mejora representa una ventaja significativa, especialmente en el análisis de imágenes hiperespectrales urbanas, donde los datacubos suelen tener dimensiones considerables. La capacidad de reducir drásticamente los tiempos de procesamiento no solo optimiza el análisis en entornos de alta demanda computacional, sino que también abre la posibilidad de abordar problemas más complejos en menor tiempo, promoviendo aplicaciones más eficientes y escalables en campos como la teledetección, la planificación urbana y la gestión ambiental.

En este trabajo se demostró que las herramientas y librerías del dominio del código abierto son una alternativa eficaz en la detección de materiales en imágenes hiperespectrales a las herramientas propietarias de análisis y procesamientos de imágenes espectrales, dados los altos costos que representan estas herramientas para la comunidad académica. En este sentido, la librería spectral fue de gran utilidad para la obtención de los datos de las bandas espectrales de la imagen empleada en esta investigación. Del mismo modo, la librería numpy fue clave para la implementación del método de similitud diferencial espectral y para la obtención del píxel promedio. Así mismo, la librería pandas fue útil para cargar los puntos correspondientes a los

pixeles de muestra de asbesto y no asbesto. Finalmente, la librería matplotlib permitió la generación de las gráficas de los pixeles de asbesto, de los pixeles de no asbesto y del pixel característico.

Como trabajo futuro derivado de la presente investigación, se pretende mejorar la efectividad de la detección de pixeles de asbesto, mediante por ejemplo el uso de técnicas de penalización de diferencias fuera de rango, de tal modo que se pueda ampliar la diferencia entre el porcentaje de similitud mínima con pixeles de asbesto y el porcentaje de similitud máxima con pixeles de no asbesto. Del mismo modo, se pretende realizar comparaciones de eficiencia entre el método propuesto y los métodos de machine learning que han resultado efectivos en la detección de materiales en imágenes hiperespectrales.

RECONOCIMIENTO

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

REFERENCIAS

- [1] X. Zhang, “Hyperspectral image classification based on convolutional neural network,” *Appl. Comput. Eng.*, vol. 42, no. 1, pp. 239–242, Feb. 2024, doi: 10.54254/2755-2721/42/20230783.
- [2] V. K. Munipalle, U. R. Nelakuditi, M. K. C. V. S. S. , and R. R. Nidamanuri, “Ultra-high-resolution hyperspectral imagery datasets for precision agriculture applications,” *Data Br.*, vol. 55, p. 110649, Aug. 2024, doi: 10.1016/j.dib.2024.110649.
- [3] Érica S. Pinto, Gustavo Pessin, and Alan K. Rêgo Segundo, “Análise de Imagens Hiperespectrais para reconhecimento de depósitos de minério de ferro utilizando aprendizado não supervisionado,” *Oct.* 2022. doi: 10.20906/CBA2022/3462.
- [4] Alanazi, N. H. A. Wahab, and B. A. S. Al-Rimy, “Hyperspectral Imaging for Remote Sensing and Agriculture: A Comparative Study of Transformer-based Models,” in *2024 IEEE 14th Symposium on Computer Applications & Industrial Electronics (ISCAIE)*, May 2024, pp. 129–136. doi: 10.1109/ISCAIE61308.2024.10576233.
- [5] Y. E. García-Vera, A. Polochè-Arango, C. A. Mendivelso-Fajardo, and F. J. Gutiérrez-Bernal, “Hyperspectral Image Analysis and Machine Learning Techniques for Crop Disease Detection and Identification: A Review,” *Sustainability*, vol. 16, no. 14, p. 6064, Jul. 2024, doi: 10.3390/su16146064.
- [6] C. Vairavan, B. M. Kamble, A. G. Durgude, S. R. Ingle, and K. Pugazenthi, “Hyperspectral Imaging of Soil and Crop: A Review,” *J. Exp. Agric. Int.*, vol. 46, no. 1, pp. 48–61, Jan. 2024, doi: 10.9734/jeai/2024/v46i12290.
- [7] C. Harsha Vardhan, R. S. Vaddi, J. Kadavakollu, and K. Kalpana, “Classification of Hyperspectral Remote Sensing Images Using Deep Learning,” 2024, pp. 349–358. doi: 10.1007/978-981-99-6547-2_27.
- [8] S. Qian, “Overview of Hyperspectral Imaging Remote Sensing from Satellites,” in *Advances in Hyperspectral Image Processing Techniques*, Wiley, 2022, pp. 41–66. doi: 10.1002/9781119687788.ch2.
- [9] M. Akewar and M. Chandak, “Hyperspectral Imaging Algorithms and Applications: A Review.” *Jan.* 02, 2024. doi: 10.36227/techrxiv.24743562.v2.
- [10] R. J. Murphy, M. J. Van Kranendonk, S. J. Kelloway, and I. E. Wainwright, “Complex patterns in fossilized stromatolites revealed by hyperspectral imaging (400–2496 nm),” *Geobiology*, vol. 14, no. 5, pp. 419–439, Sep. 2016, doi: 10.1111/gbi.12184.
- [11] N. Zaini, F. Van der Meer, and H. Van der Werff, “Determination of Carbonate Rock Chemistry Using Laboratory-Based Hyperspectral Imagery,” *Remote Sens.*, vol. 6, no. 5, pp. 4149–4172, May 2014, doi: 10.3390/rs6054149.
- [12] E. A. MacLagan, E. L. Walton, C. D. K. Herd, and B. Rivard, “Hyperspectral imaging of drill core from the Steen River impact structure, Canada: Implications for hydrothermal activity and formation of suevite-like breccias,” *Meteorit. Planet. Sci.*, vol. 55, no. 7, pp. 1564–1580, Jul. 2020, doi: 10.1111/maps.13388.
- [13] D. Manolakis, E. Truslow, M. Pieper, T. Cooley, and M. Brueggeman, “Detection Algorithms in Hyperspectral Imaging Systems: An Overview of Practical Algorithms,” *IEEE Signal Process. Mag.*, vol. 31, no. 1, pp. 24–33, Jan. 2014, doi: 10.1109/MSP.2013.2278915.
- [14] M. Shimoni, R. Haelterman, and C. Perneel, “Hypersectral Imaging for Military and Security Applications: Combining Myriad

- Processing and Sensing Techniques,” *IEEE Geosci. Remote Sens. Mag.*, vol. 7, no. 2, pp. 101–117, Jun. 2019, doi: 10.1109/MGRS.2019.2902525.
- [15] X. Briottet et al., “Military applications of hyperspectral imagery,” in *Defense and Security Symposium*, May 2006, p. 62390B. doi: 10.1117/12.672030.
- [16] E. Viero, D. Gubiani, M. Basso, M. Marin, and G. Sgrazutti, “Identification of asbestos roofing from hyperspectral images.” Mar. 09, 2024. doi: 10.5194/egusphere-egu24-15565.
- [17] 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.
- [18] G. Bonifazi et al., “Asbestos detection in construction and demolition waste by different classification methods applied to short-wave infrared hyperspectral images,” *Spectrochim. Acta Part A Mol. Biomol. Spectrosc.*, vol. 307, p. 123672, Feb. 2024, doi: 10.1016/j.saa.2023.123672.
- [19] D. Enrique Valdelamar Martínez, M. Saba, and L. K. Torres Gil, “Assessment of asbestos-cement roof distribution and prioritized intervention approaches through hyperspectral imaging,” *Heliyon*, vol. 10, no. 3, p. e25612, Feb. 2024, doi: 10.1016/j.heliyon.2024.e25612.
- [20] D. D. Langer, T. A. Johansen, and A. J. Sorensen, “Interactive Hyperspectral Data Inspection During Field Operations,” in *2022 12th Workshop on Hyperspectral Imaging and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, Sep. 2022, pp. 1–5. doi: 10.1109/WHISPERS56178.2022.9955108.
- [21] V. K. Muniapalle, U. Rani Nelakuditi, and R. R. Nidamanuri, “Impact of Dimensionality Reduction Techniques on Classification of Hyperspectral Images,” in *2023 3rd International Conference on Intelligent Technologies (CONIT)*, Jun. 2023, pp. 1–6. doi: 10.1109/CONIT59222.2023.10205828.
- [22] J. M. Haut, J. M. Franco-Valiente, M. E. Paoletti, S. Moreno-Álvarez, and A. Pardo-Díaz, “Hyperspectral Image Analysis Using Cloud-Based Support Vector Machines,” *SN Comput. Sci.*, vol. 5, no. 6, p. 719, Jul. 2024, doi: 10.1007/s42979-024-03073-z.
- [23] S. Li, W. Song, L. Fang, Y. Chen, P. Ghamisi, and J. A. Benediktsson, “Deep Learning for Hyperspectral Image Classification: An Overview,” *IEEE Trans. Geosci. Remote Sens.*, vol. 57, no. 9, pp. 6690–6709, Sep. 2019, doi: 10.1109/TGRS.2019.2907932.
- [24] Plaza et al., “Recent advances in techniques for hyperspectral image processing,” *Remote Sens. Environ.*, vol. 113, pp. S110–S122, Sep. 2009, doi: 10.1016/j.rse.2007.07.028.
- [25] K. Saheb Etabaa and M. Ben Salem, “Adaptive Progressive Band Selection for Dimensionality Reduction in Hyperspectral Images,” *J. Indian Soc. Remote Sens.*, vol. 46, no. 2, pp. 157–167, Feb. 2018, doi: 10.1007/s12524-017-0691-9.
- [26] Elmaizi, H. Nhaila, E. Sarhrouni, A. Hammouch, and C. Nacir, “A novel information gain based approach for classification and dimensionality reduction of hyperspectral images,” *Procedia Comput. Sci.*, vol. 148, pp. 126–134, 2019, doi: 10.1016/j.procs.2019.01.016.
- [27] 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.
- [28] Z. Chao, F. Xianchuang, W. Tong, Z. Yuanzhi, and C. Shengbo, “Detection of Ore-Forming Elements Migrated From Rock and Soil to Vegetation Leaves Using Hyperspectral Data,” *Radio Sci.*, vol. 58, no. 8, Aug. 2023, doi: 10.1029/2022RS007580.
- [29] N. OWADA, M. TOBITA, B. SINAICE, H. TORIYA, S. UTSUKI, and Y. KAWAMURA, “Development of Asbestos Containing Serpentine Identification Method Using Hyperspectral Imaging,” *Int. J. Soc. Mater. Eng. Resour.*, vol. 25, no. 2, pp. 189–194, Oct. 2022, doi: 10.5188/ijsmr.25.189.
- [30] Y. Jeong, J. Yu, L. Wang, and H.-C. Kim, “Spatial Assessment of Asbestos Mine Remediation Effect Using Airborne Hyperspectral Imaging System.” May 15, 2023. doi: 10.5194/egusphere-egu23-1693.