

Análisis de Fourier para la detección de vegetación en imágenes hiperespectrales

Fourier analysis for detecting vegetation in hyperspectral images

Gabriel E. Chanchí-Golondrino¹   Manuel A. Ospina-Alarcón¹  Manuel Saba¹ 

¹Universidad de Cartagena, Facultad de Ingeniería, Cartagena de Indias, Colombia

Resumen

Introducción: las imágenes hiperespectrales, a diferencia de las imágenes convencionales, están compuestas por numerosos canales que proporcionan información detallada sobre las firmas espectrales de los objetos. Esto permite identificar los materiales que los componen y, dada su potencialidad en la detección de cambios ambientales, se vuelve relevante la identificación de vegetación en entornos urbanos mediante métodos computacionales eficaces.

Objetivo: el objetivo de esta investigación es proponer un método computacional basado en análisis de Fourier para la detección de vegetación en imágenes hiperespectrales.

Metodología: la investigación se desarrolló en cuatro fases metodológicas: selección de tecnologías, obtención del píxel característico de vegetación, determinación de la similitud de fase entre el píxel característico y los píxeles de vegetación y no vegetación, validación del método en una imagen hiperespectral de prueba. Se implementó un método utilizando las librerías spectral y numpy de Python.

Resultados: el análisis de Fourier obtuvo una similitud de fase promedio de 89.89% y una similitud mínima de 64.54% entre el píxel característico de vegetación y 100 píxeles de vegetación de entrenamiento. Para los píxeles de no vegetación, la similitud de fase promedio fue de 42.19%, con una similitud máxima de 63.98%. Estos resultados indican que el método propuesto logra diferenciar adecuadamente entre píxeles de vegetación y no vegetación.

Conclusiones: los resultados demuestran que el método basado en análisis de Fourier puede identificar con precisión las zonas de vegetación en imágenes hiperespectrales, mostrando similitudes de fase que no se superponen entre vegetación y no vegetación. Esto valida la eficacia del enfoque propuesto en la detección de vegetación en entornos urbanos.

Palabras clave: análisis de Fourier, detección de vegetación, imágenes hiperespectrales, visión por computador, sensado remoto.

Abstract

Introduction: hyperspectral images, unlike conventional images, are composed of numerous channels that provide detailed information about the spectral signatures of objects. This allows for the identification of the materials that make them up, and given their potential for detecting environmental changes, identifying vegetation in urban settings using effective computational methods becomes relevant.

Objective: the objective of this research is to propose a computational method based on Fourier analysis for detecting vegetation in hyperspectral images.

Methods: the research was developed in four methodological phases: selection of technologies, acquisition of the characteristic vegetation pixel, determination of phase similarity between the characteristic pixel and vegetation and non-vegetation pixels, validation of the method on a test hyperspectral image. A method was implemented using the spectral and numpy libraries in Python.

Results: the Fourier analysis yielded an average phase similarity of 89.89% and a minimum similarity of 64.54% between the characteristic vegetation pixel and 100 training vegetation pixels. For non-vegetation pixels, the average phase similarity was 42.19%, with a maximum similarity of 63.98%. These results indicate that the proposed method successfully differentiates between vegetation and non-vegetation pixels.

Conclusion: the results demonstrate that the Fourier-based method can accurately identify vegetation areas in hyperspectral images, showing non-overlapping phase similarities between vegetation and non-vegetation. This validates the effectiveness of the proposed approach in detecting vegetation in urban environments.

Keywords: computer vision, fourier analysis, hyperspectral imaging, vegetation detection, remote sensing.

¿Cómo citar

Chanchí-Golondrino, G.E., Ospina-Alarcón, M.A., Saba, M. Análisis de Fourier para la detección de vegetación en imágenes hiperespectrales. Ingeniería y Competitividad, 2024, 26(3)e-21013493

<https://doi.org/10.25100/iyc.v26i3.13493>

Recibido: 12-01-24

Evaluado: 30-04-24

Aceptado: 21-06-24

Online: 8-10-24



Correspondencia

gchanchig@unicartagena.edu.co



CrossMark



¿Por qué se llevó a cabo?

A diferencia de las imágenes convencionales, las imágenes hiperespectrales se componen de numerosos canales o bandas, que proporcionan información detallada sobre las firmas espectrales de los objetos en las imágenes, permitiendo identificar los materiales que los componen. En este contexto, uno de los desafíos clave es la identificación y evaluación de nuevos métodos computacionales diferentes a los convencionales, que permitan la detección de materiales como la vegetación. Así, en este artículo se propuso el uso de la similitud de fase de Fourier para la detección de firmas espectrales de vegetación en imágenes hiperespectrales.

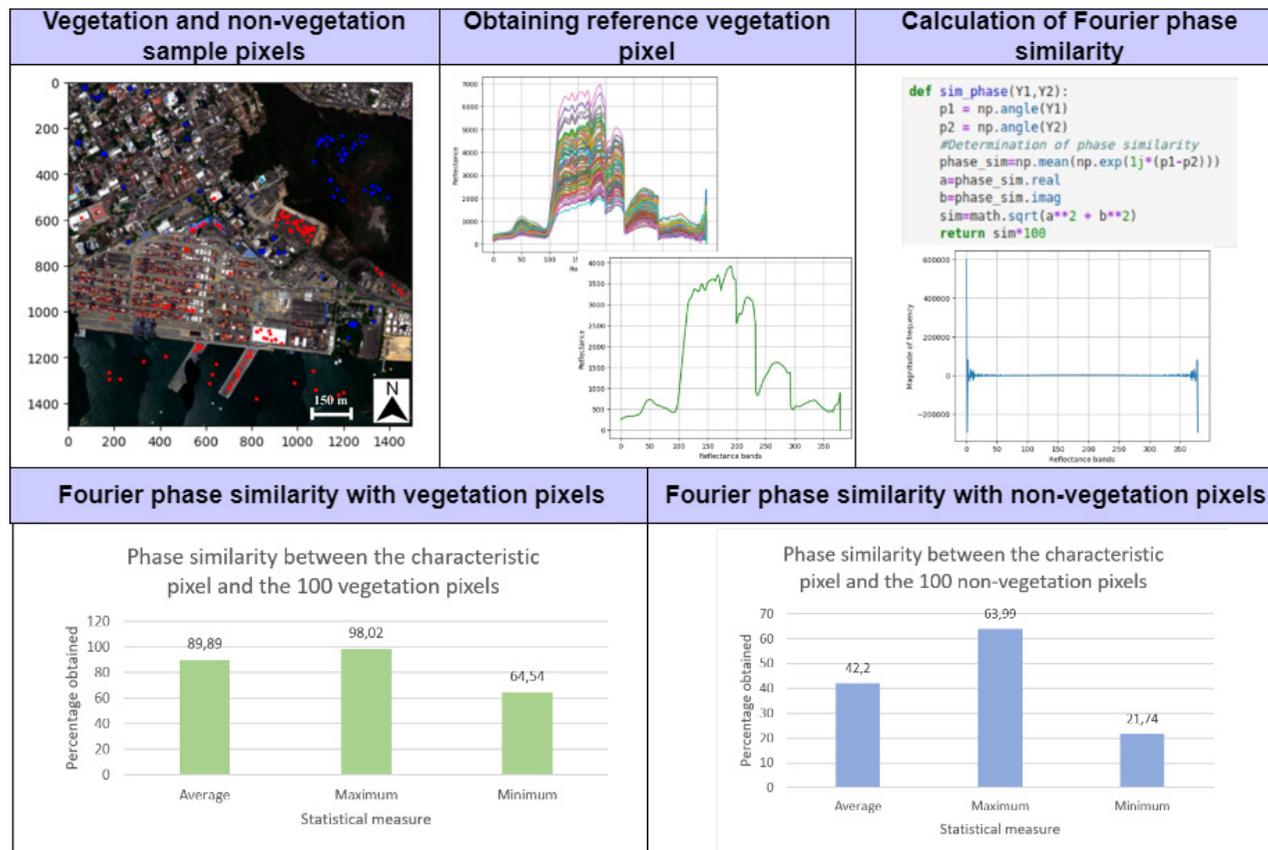
¿Los resultados más relevantes?

Utilizando bibliotecas de código abierto, se implementó y evaluó el método de similitud de Fourier con píxeles de muestra de vegetación y no vegetación. Al operar el píxel de vegetación característico con los píxeles de muestra de vegetación, se obtuvo una similitud promedio de 89,89% y una similitud de fase mínima de 64,54%. De manera similar, al operar el píxel característico con píxeles sin vegetación, se obtuvo una similitud de fase promedio del 42,19% y una similitud de fase máxima del 63,98%. Los resultados demuestran que el método propuesto distingue efectivamente entre píxeles con vegetación y sin vegetación, con similitudes de fase en ambos casos que no se superponen.

¿Qué aportan estos resultados?

Los resultados obtenidos permitieron identificar el método de similitud de fases de Fourier como una alternativa viable a los métodos tradicionales de identificación de materiales, como los basados en correlación y aprendizaje automático, proporcionando un rendimiento computacional potencialmente mejor que estos últimos. Por tanto, este trabajo se puede extrapolar a la evaluación de la eficacia del método en la detección de diferentes materiales.

Graphical Abstract



Introducción

Para la consolidación de un entorno urbano racional con respecto al medio ambiente y la agricultura sostenible, es crucial poseer un mayor conocimiento sobre la vegetación, los suelos, los cultivos, los bosques, el agua y otros recursos relevantes. Esto implica aprovechar la tecnología de vanguardia para la detección y clasificación de materiales, ejemplificada por imágenes hiperespectrales (1,2). Las imágenes hiperespectrales se adquieren mediante la aplicación de técnicas de teledetección (RS), en las que los sensores aéreos se utilizan para capturar información espacial, temporal y espectral de un material u objeto sin contacto físico (en la superficie, en la atmósfera y en los océanos). Esto se logra mediante la utilización de señales propagadas, como la radiación electromagnética (3,4).

Una imagen hiperespectral es aquella que abarca múltiples bandas de información espectral en todo el espectro electromagnético, lo que permite la detección de elementos de interés u objetos a través de la comparación de curvas espectrales o firmas derivadas de diferentes bandas dentro de la imagen (5). En concreto, las imágenes hiperespectrales se centran en la región de reflectancia solar que abarca desde 400 nm hasta 2500 nm, cubriendo el espectro visible (VIS), el infrarrojo visible (NIR) y el infrarrojo de onda corta (SWIR) (6,7). En el contexto de las imágenes hiperespectrales, se generan estructuras de datos conocidas como hiper cubos o cubos de datos (imágenes 3D), obtenidas combinando dimensiones espaciales con una tercera dimensión espectral (8–11). El estudio de las imágenes hiperespectrales facilita así el desarrollo de soluciones prácticas que permitan la comprensión, caracterización y modelización de los recursos naturales, así como fomentar el seguimiento de su dinámica tanto en el tiempo como en el espacio (1).

Las imágenes hiperespectrales tienen diversas aplicaciones en diferentes campos, abarcando un amplio espectro de usos (12). Estas aplicaciones van desde la vigilancia militar (13), donde estas imágenes se han utilizado para recopilar información detallada en contextos de seguridad, para la detección de plagas y enfermedades en los cultivos (14), que permite un diagnóstico precoz y preciso. En el campo de la gestión forestal, estas imágenes se han empleado en el seguimiento y control de los recursos forestales (15). La capacidad de las imágenes hiperespectrales para analizar la composición del material se refleja en su aplicación en la determinación de la fermentación de las semillas de cultivos (16) y en la identificación y caracterización de recursos minerales y metales (17). Además, estas imágenes también han incursionado en el ámbito astronómico, permitiendo determinar la composición química de las estrellas (18). A pesar de la adopción generalizada de estas técnicas, uno de los principales desafíos radica en el desarrollo de métodos eficientes para procesar los grandes volúmenes de información generados por cubos de datos de imágenes hiperespectrales. Estos métodos deben permitir una detección eficaz de materiales basada en sus firmas espectrales (1,9,18–20). En este contexto, el uso de técnicas de aprendizaje automático, en particular el aprendizaje supervisado, requiere un número suficiente de muestras para entrenar los modelos (21). Por lo tanto, es crucial evaluar y comparar varios enfoques computacionales que permiten la detección precisa de materiales en imágenes hiperespectrales en función de sus firmas espectrales.

Además, estas imágenes tienen aplicaciones en el monitoreo ambiental, permitiendo la observación de cambios en la temperatura terrestre, los océanos y la topografía submarina (22,23). Del mismo modo, son cruciales para cartografiar incendios forestales a gran escala, rastrear nubes y contribuir a la predicción del clima (24). Además, tienen la capacidad de observar erupciones volcánicas y monitorear tormentas de material particulado (25). Dentro de su amplia gama de aplicaciones, las imágenes hiperespectrales también son esenciales en la planificación urbana, la geología, la exploración de petróleo y gas, y otras áreas (26). Estas imágenes facilitan el seguimiento del desarrollo urbano a través de análisis multitemporales, la identificación de objetos del suelo, como tejados de fibrocemento, y apoyan los esfuerzos humanitarios y de planificación en diversas disciplinas.

En esta misma línea, dentro del vasto panorama de los métodos de análisis de imágenes hiperespectrales, se han destacado varios enfoques, que han atraído una atención considerable en la investigación y la aplicación. Entre estos métodos, las métricas de distancia/correlación y el aprendizaje automático han surgido como enfoques ampliamente estudiados y reconocidos. Las métricas de distancia/correlación se basan en la comparación de las firmas espectrales de diferentes píxeles, lo que permite evaluar la similitud entre ellos y extraer información valiosa sobre los materiales presentes en la imagen (27). Por otro lado, el aprendizaje automático ofrece la capacidad de desarrollar modelos predictivos sofisticados a partir de grandes conjuntos de datos, lo que permite una clasificación y detección precisas de materiales y objetos (28). Sin embargo, es importante destacar que, dentro de este panorama tan diverso, existen métodos que aún no han recibido el mismo nivel de atención, como los basados en el análisis de Fourier. A pesar de su importante potencial para descomponer señales espectrales y revelar patrones ocultos, estos métodos han sido relativamente menos explorados en comparación con las métricas de distancia/correlación y el aprendizaje automático. Esta brecha en el estudio pone de relieve una oportunidad intrigante para ampliar la comprensión, el conocimiento y la utilización de los beneficios que los métodos basados en el análisis de Fourier podrían aportar al análisis de imágenes hiperespectrales.

En este trabajo, proponemos una contribución novedosa en forma de un nuevo método basado en el análisis de Fourier, específicamente utilizando la similitud de fase de Fourier, para la identificación y/o detección de vegetación en el contexto de imágenes hiperespectrales. Para implementar el método, se obtuvo un píxel característico asociado con la firma espectral de la vegetación, de modo que se evaluó la precisión del método en comparación con 100 píxeles de vegetación y 100 píxeles de no vegetación, cada uno de los cuales comprende 380 bandas de frecuencia. Tras la determinación de la eficacia del método propuesto, se validó una imagen hiperespectral del barrio Manga, en Cartagena de Indias, compuesta por 1500 x 1500 píxeles y 380 bandas. El método propuesto se implementó utilizando bibliotecas de código abierto en el lenguaje Python, como spectral, pandas, numpy y matplotlib. A partir de los resultados obtenidos con el método propuesto, este enfoque pretende ser extrapolado en el contexto académico y de investigación para la implementación de métodos de detección de diversos tipos de materiales dentro del contexto ambiental, con el objetivo de facilitar el seguimiento temporal de la distribución de estos materiales en el contexto urbano.

El resto del artículo se organiza de la siguiente manera: en la sección 2 se presentan las diferentes fases metodológicas empleadas para el desarrollo de la presente investigación. En la sección 3 se describen los resultados obtenidos en este estudio, incluyendo la derivación del píxel característico de vegetación, la evaluación del método con un conjunto de píxeles de prueba (100 píxeles de vegetación y 100 píxeles de no vegetación), así como la validación con una imagen hiperespectral correspondiente al barrio Manga en la ciudad de Cartagena de Indias. Finalmente, en la sección 4 se presentan las conclusiones y los trabajos futuros derivados de esta investigación.

Metodología

Para el desarrollo de esta investigación se definieron cuatro fases metodológicas: selección de tecnologías para el procesamiento y análisis de imágenes hiperespectrales, obtención del píxel característico o píxel promedio, determinación de la similitud de la fase de Fourier entre el píxel de vegetación y los píxeles de muestra (vegetación y no vegetación), y finalmente validación del método en una imagen de prueba hiperespectral (ver Figura 1).

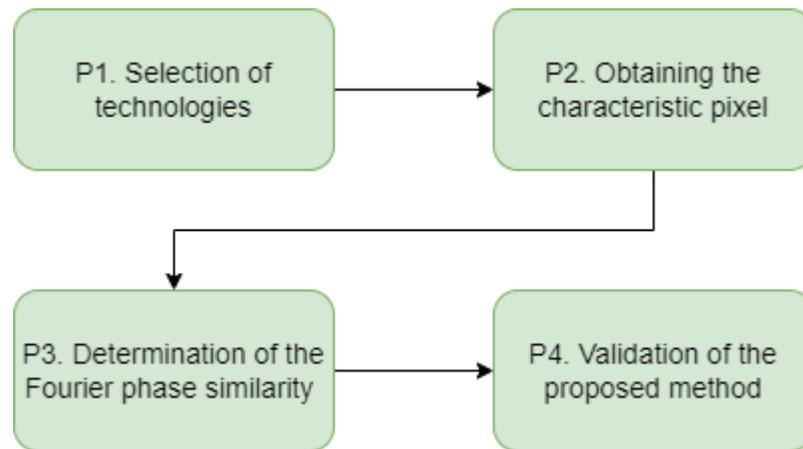


Figura 1. Metodología considerada. Fuente: elaboración propia.

En la primera fase de la metodología, se eligió inicialmente la biblioteca espectral en Python para la lectura y procesamiento de las diferentes bandas o capas de la imagen hiperespectral utilizada en esta investigación. Además, se seleccionó la biblioteca numpy en Python para obtener la transformada de Fourier de cada píxel de la imagen, así como para calcular la similitud de fase entre píxeles. Además, se utilizaron las ventajas proporcionadas por la biblioteca matplotlib en Python para trazar los diferentes píxeles de la imagen hiperespectral.

En la segunda fase de la metodología, se seleccionó un conjunto de 100 píxeles de vegetación y 100 píxeles de no vegetación de una imagen hiperespectral de prueba para la posterior evaluación del modelo. A partir de los 100 píxeles de vegetación, se derivó el píxel promedio o el píxel de vegetación característico, que representa las firmas espectrales de los 100 píxeles de vegetación. Por lo tanto, el píxel característico o promedio consiste en una matriz con 380 posiciones, cada una de las cuales contiene la reflectancia promedio de la banda espectral n-ésima de los 100 píxeles de vegetación seleccionados. Este enfoque es adecuado para trabajar con la transformada de Fourier, ya que permite la descomposición de una señal en sus componentes de frecuencia, proporcionando así información sobre la distribución de frecuencias.

En la tercera fase, a partir del píxel característico de la vegetación, se calculó la similitud de la fase de Fourier entre el píxel característico y cada uno de los 100 píxeles de vegetación y no vegetación. El objetivo era evaluar la precisión del método propuesto y, en consecuencia, su capacidad para diferenciar entre píxeles de vegetación y otros píxeles. Para este propósito, tanto el píxel característico como los otros píxeles se sometieron a una transformada rápida de Fourier utilizando los métodos proporcionados por la biblioteca numpy. Por lo tanto, la ecuación (1) representa la transformada rápida de Fourier aplicada a cada píxel de la imagen. La transformada rápida de Fourier puede entenderse como un método computacional algorítmicamente eficiente para calcular la transformada discreta de Fourier (29).

$$X(k) = \frac{1}{N} \sum_{n=0}^{N-1} x(n) \cdot e^{-j\frac{2\pi}{N}k \cdot n} \quad (1)$$

Donde representa la signatura espectral de la imagen en función de la banda $x(n)$, n , k es la fase del espectro y N representa el número de bandas en cada imagen hiperespectral. De la misma manera, la similitud de fase calculada entre las transformadas de Fourier de cada píxel se presenta en la ecuación (2).

$$\text{similarity}(Y_1, Y_2) = \frac{1}{N} \sum_f e^{j\Delta\phi_f} \times 100 \quad (2)$$

Donde Y_1 e Y_2 corresponden a la transformada de Fourier de los 2 píxeles correlacionados de 380 bandas, es decir, en este caso, Y_1 se refiere a la transformada de Fourier del píxel característico e Y_2 corresponde a la transformada de Fourier del píxel evaluado. Del mismo modo, corresponde al número total de frecuencias en las señales N , mientras que es la diferencia de fase en la frecuencia, definida en la Ecuación (3) como:

$$\Delta\phi_f = \angle Y_1(f) - \angle Y_2(f) \quad (3)$$

Del mismo modo, representa la exponencial compleja de la diferencia de fase en la frecuencia, y es la suma de todas las frecuencias. Por lo tanto, la ecuación (2) calcula la similitud entre las fases de las dos señales en cada frecuencia, y luego promedia estos valores en todas las frecuencias (30).

Finalmente, en la cuarta fase de la metodología, y una vez evaluado el método propuesto, se aplicó este método a todos los píxeles de una imagen de prueba de 1500 x 1500 píxeles con 380 bandas por píxel (ver Figura 2), correspondiente al barrio Manga de Cartagena. De esta forma, se resaltaban en la imagen los píxeles que superaban un determinado umbral de similitud con respecto al píxel medio o característico.

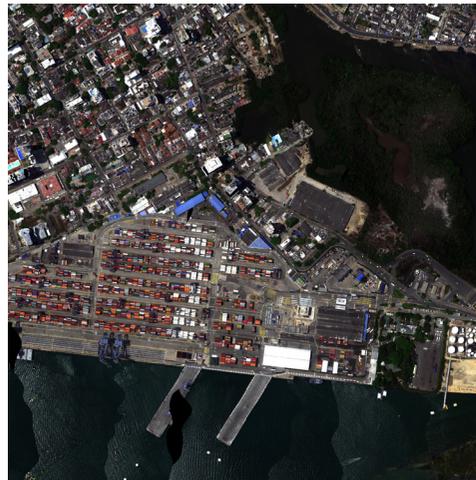


Figura 3. Imagen hiperespectral de referencia considerada en el estudio. Fuente: elaboración propia.

Resultados y discusión

Como se mencionó en la metodología de este estudio, inicialmente, se tomó una muestra de 100 píxeles de vegetación y no vegetación de la imagen presentada en la figura 2 para evaluar la precisión del método basado en el análisis de Fourier. En la figura 3, los 100 píxeles de vegetación seleccionados se muestran en azul, mientras que los píxeles no vegetales (agua, techos, contenedores, carreteras, automóviles, entre otros) se presentan en rojo. Cabe destacar que, a diferencia de los píxeles de una imagen RGB convencional, que cuentan con 3 canales de color (rojo, verde y azul), cada píxel de la imagen hiperespectral considerada en este caso tiene un total de 380 bandas espectrales. Estas bandas forman la firma espectral de los materiales a partir de los cuales se muestrearon los píxeles. Al trazar la reflectancia de las 380 bandas correspondientes a los 100 píxeles de vegetación, la forma de la curva es similar porque las 380 bandas reflejan la reflectancia específica de la vegetación. Por el contrario, los 100 píxeles no vegetales incluyen las firmas espectrales de diferentes materiales, ya que los valores de reflectancia de las 380 bandas

varían según el material. Así, las 100 firmas espectrales de los píxeles de vegetación proporcionan suficiente información sobre este material en sus 380 bandas para ser utilizada en la caracterización de la vegetación.

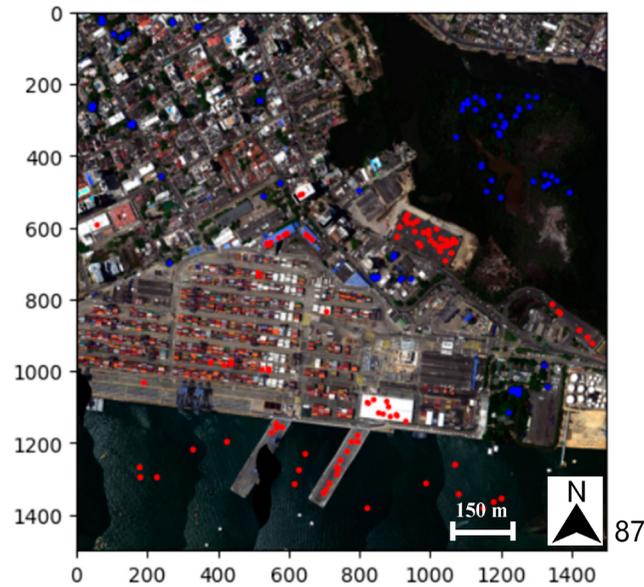


Figura 3. Píxeles de muestra seleccionados. Fuente: elaboración propia.

A partir de los 100 píxeles de vegetación de la muestra, el píxel característico de la firma espectral de la vegetación se obtuvo promediando los 100 píxeles utilizando la biblioteca numpy. Por lo tanto, la figura 4 presenta tanto el grupo de 100 píxeles como el píxel característico derivado del promedio de los mismos.

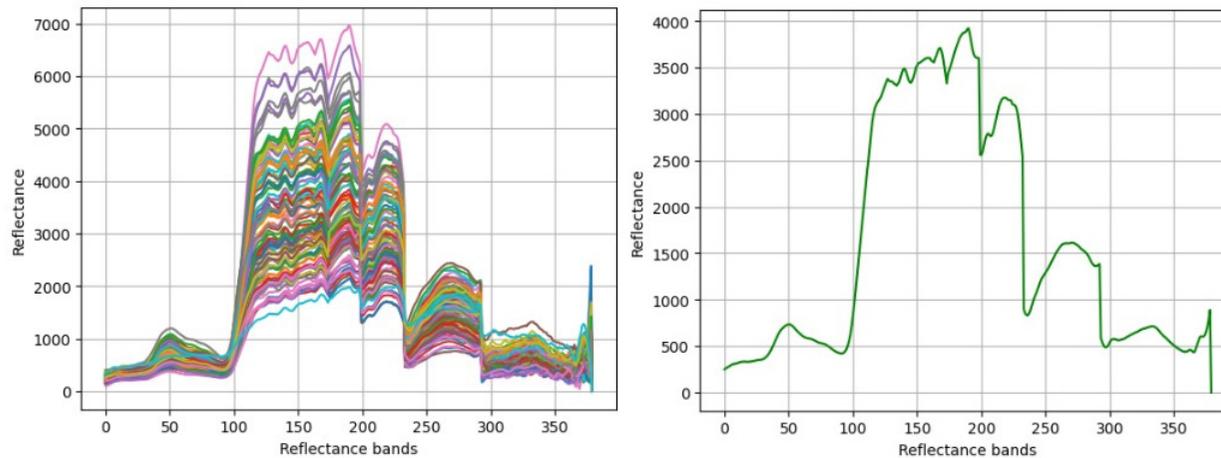


Figura 4. Píxel característico de la vegetación. Fuente: elaboración propia.

Así, a partir de la figura 4, se puede observar que el píxel característico o promedio corresponde a una matriz de 380 posiciones, donde cada posición representa la reflectancia promedio de la banda n-ésima de 100 píxeles de muestra de vegetación. Cada píxel de muestra incluido en el promedio tiene 380 bandas de reflectancia. Utilizando el píxel característico de la figura 4, la similitud de fase con los 100 píxeles de vegetación y no vegetación se obtuvo mediante la implementación computacional de las ecuaciones (1), (2) y (3). Por lo tanto, la figura 5 ilustra la implementación de una función de Python que determina la similitud de fase de Fourier, tomando como parámetros

las transformadas rápidas de Fourier de los dos píxeles para correlacionarlas. Como se muestra en la figura 5, la similitud de fase se implementó utilizando las funcionalidades proporcionadas por la biblioteca numpy en Python.

```
def sim_phase(Y1,Y2):
    p1 = np.angle(Y1)
    p2 = np.angle(Y2)
    #Determination of phase similarity
    phase_sim=np.mean(np.exp(1j*(p1-p2)))
    a=phase_sim.real
    b=phase_sim.imag
    sim=math.sqrt(a**2 + b**2)
    return sim*100
```

Figura 5. Implementación de la función de similitud de fases. Fuente: elaboración propia.

Por otro lado, en la figura 6 se presenta la transformada rápida de Fourier obtenida para el caso del píxel promedio, la cual se correlaciona utilizando el algoritmo mostrado en la figura 5 con los diferentes píxeles seleccionados. Si bien a partir de la figura 6 es posible observar que la transformada de Fourier del píxel característico no está centrada, es importante mencionar que el análisis que busca determinar si un píxel corresponde a vegetación no se realiza directamente desde la transformada, sino más bien desde la similitud de fase o fase relativa entre los dos píxeles.

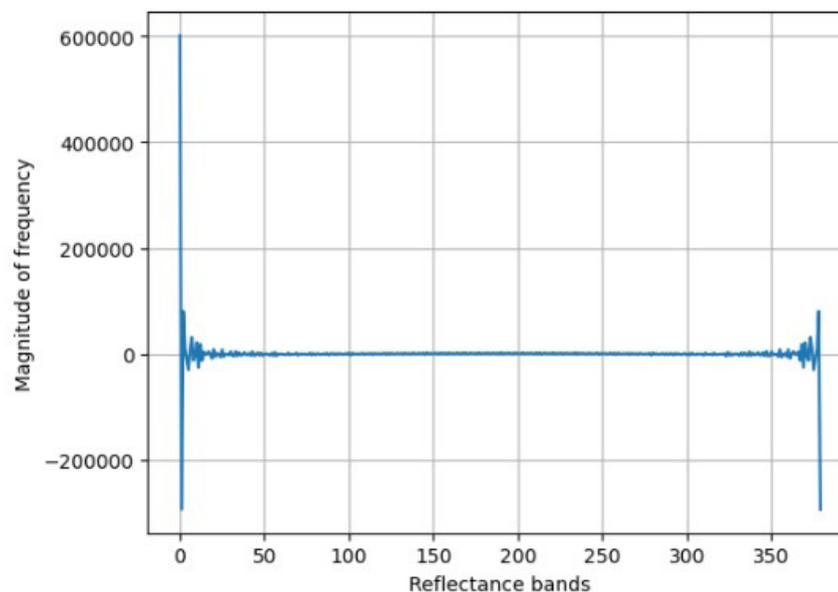


Figura 6. Transformada rápida de Fourier del píxel característico. Fuente: elaboración propia.

Al determinar la similitud de fase entre el píxel promedio o característico y cada uno de los 100 píxeles de vegetación, es posible observar en la figura 7 que la similitud promedio obtenida fue de 89.89%, con un valor máximo de similitud de 98.02% y un valor mínimo de 64.54%. Del mismo modo, la desviación estándar obtenida entre las similitudes de fase fue de 6,86. Asimismo, el umbral mínimo que no se debe superar al analizar píxeles no vegetales es del 64,54%.

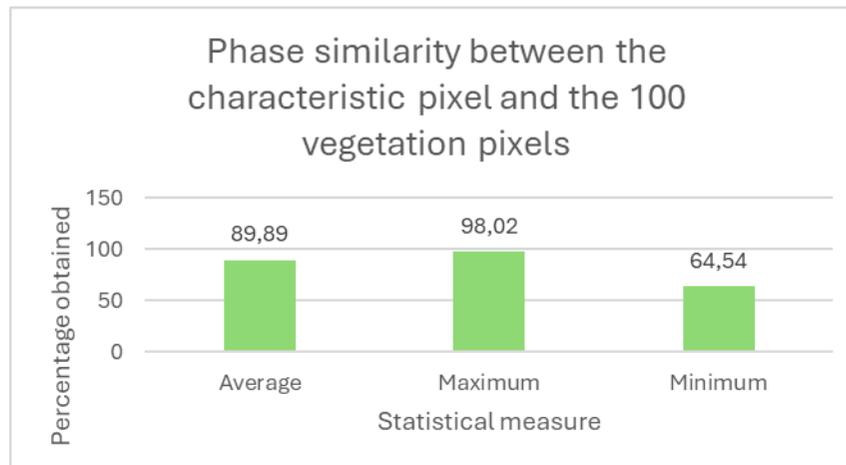


Figura 7. Resultados obtenidos con píxeles de vegetación. Fuente: elaboración propia.

De igual forma, al calcular la similitud de fase entre el píxel promedio o característico y cada uno de los 100 píxeles no vegetales, es posible observar en la figura 8 que la similitud promedio obtenida fue de 42.2%, con un valor máximo de similitud de 63.99% y un valor mínimo de 21.74%. Del mismo modo, la desviación estándar obtenida entre las similitudes de fase fue de 7,15. De la misma forma, el umbral máximo para los píxeles no vegetales, que se utilizará para la comparación con el umbral mínimo para la vegetación, se establece en el 63,99%.

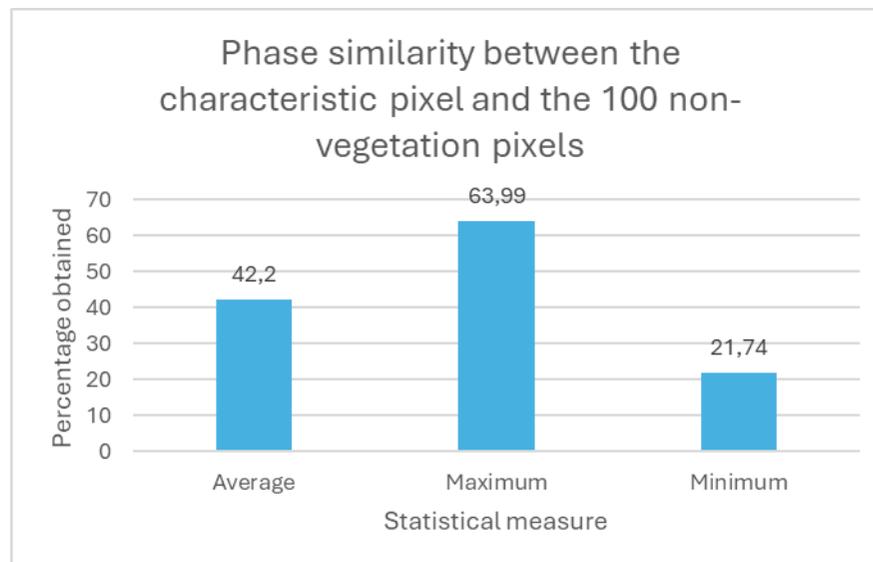


Figura 8. Resultados obtenidos con píxeles no vegetales. Fuente: elaboración propia.

Al comparar el umbral mínimo de vegetación (64,54%) con el umbral máximo de no vegetación (63,99%), se evidencia que, a pesar de la diferencia de 0,55% entre ellos, estos valores no se superponen. Por lo tanto, el método basado en el análisis de Fourier, centrándose específicamente en la similitud de fase de Fourier, se puede utilizar para la detección de vegetación en imágenes hiperspectrales, tomando el umbral mínimo de comparación del 64,54%. En este sentido, es posible observar que los valores de reflectancia de las 380 bandas correspondientes a los 100 píxeles de vegetación seleccionados de la imagen hiperspectral considerada permitieron una adecuada caracterización de la firma espectral de la vegetación. Esto indica que el píxel promedio obtenido capturó con precisión la información sobre los diversos cambios en la curva espectral

a través de las 380 bandas. Por otro lado, es importante mencionar que, si bien la transformada de Fourier obtenida de píxeles de vegetación no está centrada, la similitud de fase entre las transformadas de Fourier de estos píxeles permite una ligera diferenciación con respecto a píxeles de otros materiales.

Luego de evaluar y comparar el método con píxeles de vegetación y no vegetación, se correlacionó el píxel característico con los 2.250.000 píxeles de 380 bandas presentes en la imagen de prueba correspondiente al barrio Manga de Cartagena. Así, en la figura 9, se muestra el algoritmo empleado para la detección de vegetación en la imagen hiperespectral, utilizando un valor mínimo de umbral de detección del 64,54%. De manera similar, en la figura 9, la vegetación detectada en la imagen hiperespectral de prueba se presenta en azul, aplicando el método implementado. Se puede observar que los resultados obtenidos visualmente se alinean con las áreas de vegetación mostradas en la Figura 2.

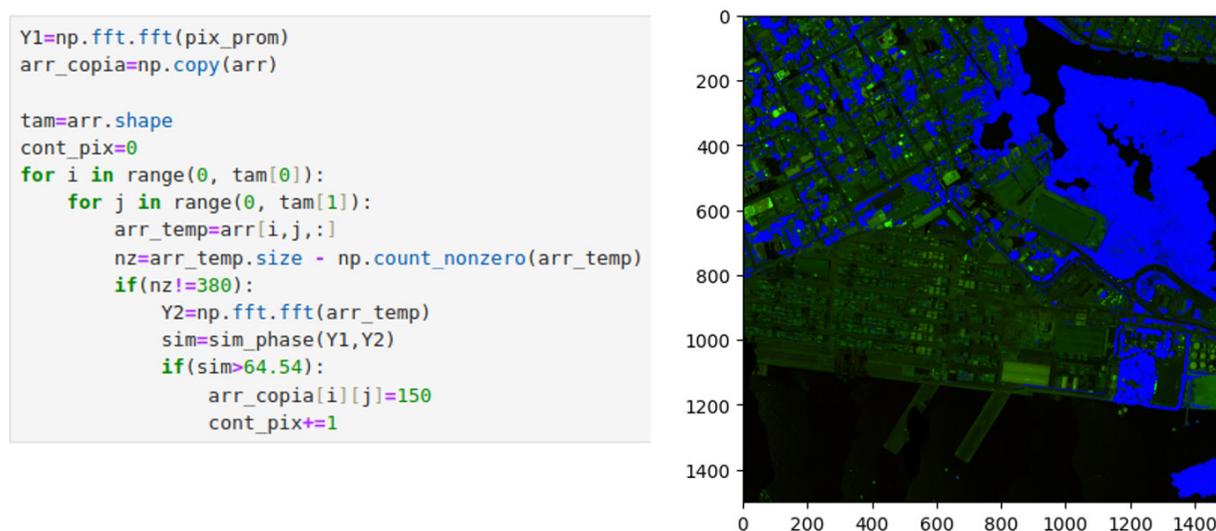


Figura 9. Aplicación del método propuesto sobre la imagen hiperespectral de ensayo. Fuente: elaboración propia.

Además, al contar los píxeles de vegetación detectados, se encontró que el método propuesto identificó un total de 452.801 píxeles de vegetación. Esto significa que los píxeles de vegetación representan el 20,12% del total de píxeles, considerando píxeles correspondientes a diversos materiales. Esto subraya la relevancia del método propuesto en el monitoreo de la vegetación u otros elementos ambientalmente significativos, como el agua, a lo largo del tiempo en el sector urbano.

En cuanto a la discusión, es importante mencionar que, en comparación con los resultados obtenidos en (27), en el que se evaluaron métodos de detección de vegetación basados en métricas de distancia y/o correlación, el método propuesto, si bien obtuvo valores de similitud promedio más bajos y valores de umbral más bajos, no muestra superposición entre los píxeles de vegetación y los píxeles de no vegetación. Por lo tanto, el método propuesto se erige como una alternativa válida para la detección de vegetación en imágenes hiperespectrales. Del mismo modo, teniendo en cuenta que la aplicación de la transformada rápida de Fourier centra los valores en fases específicas, es posible que el cálculo de similitudes sea más eficiente.

Por otro lado, en lo que respecta a la labor de (30), donde los autores utilizan la transformada rápida de Fourier para detectar cuerpos de agua en imágenes hiperespectrales, la firma espectral de los cuerpos de agua no se pudo detectar al considerar las 380 bandas. Esto dio lugar a superposiciones en los porcentajes de similitud de fase entre los píxeles de las masas de agua y otros píxeles, lo que hizo necesaria la identificación de las bandas más relevantes en las que la

similitud de fase podía distinguir adecuadamente las masas de agua. Por lo tanto, es importante mencionar que la transformada rápida de Fourier demostró una precisión adecuada en la detección de la curva característica de la vegetación. Sin embargo, para otros materiales, puede ser necesario evaluar y determinar las bandas donde la similitud de fase no se superpone, considerando que la firma espectral de cada material es diferente.

Conclusiones

En este trabajo se propone un nuevo enfoque como contribución a la identificación de la vegetación en imágenes hiperespectrales. Este enfoque se basa en el uso del análisis de Fourier, centrándose específicamente en la similitud de fase calculada entre el píxel característico de la vegetación (píxel promedio) y los otros píxeles en una imagen de prueba hiperespectral. El método propuesto pretende servir de referencia a nivel académico y para las entidades ambientales en el desarrollo de estudios ambientales, con el objetivo de identificar la distribución de la vegetación en un área urbana y monitorear los cambios en la distribución de la vegetación a lo largo del tiempo dentro de una ciudad.

Se observó que, dado que los diferentes materiales exhiben firmas espectrales distintas, existe la posibilidad de superposición de similitud de fase al abordar todas las bandas en imágenes hiperespectrales, como se evidencia en el estudio presentado en (30). Por lo tanto, se vuelve imperativo evaluar qué bandas son pertinentes para la similitud de fase para determinar con precisión la firma espectral del material. En este contexto, para la investigación descrita en este trabajo, que se centró en la detección de píxeles de vegetación, cabe destacar que la similitud de fase de Fourier no exhibió superposición. Por lo tanto, el método propuesto resulta eficaz para detectar la curva característica de la vegetación utilizando las 380 bandas de la imagen.

Si bien existen varias herramientas patentadas para el análisis y procesamiento de imágenes hiperespectrales en el contexto de los sistemas de información geográfica, este estudio demostró la utilidad y el potencial significativo de las herramientas y tecnologías de código abierto. Para procesar y acceder a píxeles y bandas en imágenes hiperespectrales, se emplearon las librerías `spectral` y `pandas` de Python. La implementación del método basado en el análisis de Fourier se benefició de las ventajas proporcionadas por la biblioteca `numpy` en Python. Finalmente, para la visualización de píxeles y la visualización de imágenes hiperespectrales, se utilizaron las bibliotecas `matplotlib` y `spectral`, respectivamente. Por lo tanto, este estudio pretende servir de referencia en cuanto a la utilización de estas herramientas en la implementación de métodos de detección de imágenes hiperespectrales dentro de contextos académicos y de investigación.

El método propuesto en este artículo resultó en una similitud promedio de 89.99% con píxeles de vegetación y una similitud de 42.2% con píxeles no vegetales (como agua, asbesto, carreteras, contenedores, entre otros). Además, el umbral mínimo detectado con píxeles de vegetación fue del 64,54%, mientras que el umbral máximo obtenido con píxeles no vegetales fue del 63,99%. Los resultados anteriores indicaron que, aunque los umbrales anteriores son cercanos, no hubo superposición entre ellos, lo que sugiere que el método puede emplearse adecuadamente para el reconocimiento de la firma espectral correspondiente a los píxeles de vegetación. Así, con base en los resultados obtenidos en esta investigación, el método propuesto puede ser considerado como una base para el desarrollo de aplicaciones de software enfocadas en el análisis y detección de diferentes tipos de materiales en imágenes hiperespectrales, considerando cada caso la firma espectral de los materiales respectivos.

La prueba de concepto desarrollada utilizando el método propuesto permitió determinar que en la imagen hiperespectral del barrio Manga de la ciudad de Cartagena de Indias, aproximadamente el 20% de los materiales detectados corresponden a vegetación. Esta prueba de concepto verificó la pertinencia del método y su significativo potencial como soporte para la realización de estudios ambientales enfocados en el monitoreo de los cambios urbanos y su impacto en el medio ambiente por parte de centros de investigación y entidades gubernamentales. Esto se logra aprovechando las ventajas que ofrece el software de código abierto para los países en desarrollo, dados los altos

costos de las licencias para el procesamiento y análisis de imágenes hiperespectrales.

Como trabajo futuro derivado de la presente investigación, se pretenden los siguientes objetivos:

a) comparar la eficiencia computacional del método propuesto con respecto a métodos basados en métricas de correlación y/o distancia; b) probar la efectividad y eficiencia del método computacional considerando las bandas de frecuencia más representativas, es decir, aquellas en las que los píxeles promedio de vegetación y no vegetación presentan la mayor diferencia; c) Analizar la eficacia del método propuesto en la detección de otros tipos de materiales, como el amianto o el agua.

Declaración de contribución de autoría de CRediT

Manuel Saba: conceptualización, análisis formal, investigación, administración de proyectos, captación de fondos, recursos, redacción, revisión y edición. Manuel A. Ospina: conceptualización, curación de datos, investigación, metodología, supervisión, validación, redacción, revisión y edición. Gabriel E. Chanchí Golondrino: Curación de datos, Análisis formal, Metodología, Software, Visualización, Redacción – borrador original.

Implicaciones éticas

Los autores no tienen ningún tipo de implicación ética que deba ser declarada en la redacción y publicación de este artículo.

Conflicto de intereses

Los autores no declaran.

Financiación

Este artículo se considera un producto en el marco del proyecto 'Desarrollo de una estrategia integral para reducir el impacto en la salud pública y el medio ambiente por la presencia de asbesto en el territorio del departamento de Bolívar', financiado por el Sistema General de Regalías de Colombia (SGR) e identificado con la clave BPIN 2020000100366. Este proyecto fue llevado a cabo por la Universidad de Cartagena, Colombia, y la Fundación Colombia Libre de Asbesto. Finalmente, los autores desean expresar su agradecimiento a Federico Frassy por su apoyo en la gestión y clasificación de datos hiperespectrales, a Aiken Hernando Ortega Heredia, María Angélica Narváez Cuadro, Carlos Andrés Castrillón Ortiz, Michelle Cecilia Montero Acosta, Margareth Peña Castro, Carlos David Arroyo Angulo, y al resto del equipo de investigación por el apoyo logístico y la recolección de muestras en campo. Además, los autores extienden su agradecimiento a Juan Manuel González de la empresa BlackSquare por su ayuda en la adquisición de datos hiperespectrales y a Sean Fitzgerald por el análisis PLM

Referencias

1. León-Pérez J. Imágenes hiperespectrales y sus aplicaciones en estudios de suelos, cultivos y bosques, en la era de la cuarta revolución industrial. *Rev UD y la Geomática*. 2021; (16):40–70.
2. Erturk A, Cesmeci D, Gullu MK, Gercek D, Erturk S. Extracción de miembros finales guiada por anomalías y regiones homogéneas para imágenes hiperespectrales. *IEEE J Sel Top Appl Earth Obs Remote Sens* [Internet]. Agosto de 2014; 7(8):3630–9. Disponible en: <https://ieeexplore.ieee.org/document/6847728/>
3. Richards JA. *Análisis de Imágenes Digitales por Teledetección* [Internet]. Berlín, Heidelberg: Springer Berlin Heidelberg; 2013. Disponible en: <https://link.springer.com/10.1007/978-3-642-30062-2>

4. Camacho-Velasco A, Vargas-García CA, Rojas-Morales FA, Castillo-Castelblanco S, Arguello-Fuentes H. Aplicaciones y retos del sensado remoto hiperespectral en la geología colombiana. *Rev Fac Ing.* 2015; 24(40):17–29.
5. Roman-Gonzales A. Análisis de imágenes hiperespectrales. *Rev Ing Desarro.* 2013; 9(35):14–7.
6. Shaw GA, Burke HK. Imágenes espectrales para teledetección. *Laboratorio Lincoln, J.* 2003; 14(1):3–28.
7. Cerra D, Muller R, Reinartz P. Reducción de ruido en imágenes hiperespectrales mediante desmezcla espectral. *IEEE Geosci Remote Sens Lett [Internet].* Enero de 2014; 11(1):109–13. Disponible en: <https://ieeexplore.ieee.org/document/6488723/>
8. Liu J, Wu Z, Xiao L, Sun J, Yan H. Regresión tensorial generalizada para la clasificación de imágenes hiperespectrales. *IEEE Trans Geosci Remote Sens [Internet].* febrero de 2020; 58(2):1244–58. Disponible en: <https://ieeexplore.ieee.org/document/8877994/>
9. Paoletti ME, Hautt J., Plaza J, Plaza A. Estudio Comparativo de Tecnicas de Clasificación de Imágenes Hiperespectrales. *Rev Iberoam Automática e Informática Ind.* 2019; (16):129–37.
10. Diezma B, Lleó L, Herrero A, Lunadei L, Roger JM, Ruiz-Altisent M. La imagen hiperespectral como herramienta de evaluación de la calidad de hortaliza de hoja mínimamente procesada. In: *VI Congreso Ibérico en Agroingeniería.* 2011. p. 1–9.
11. Li J, Li Y, Wang C, Ye X, Heidrich W. BUSIFusion: Fusión ciega no supervisada de imágenes hiperespectrales y RGB. *IEEE Trans Comput Imaging [Internet].* 2023; 9:94–105. Disponible en: <https://ieeexplore.ieee.org/document/10037221/>
12. Fan Y, Ni D, Ma H. HyperDB: una base de datos hiperespectral de clase terrestre diseñada para un sistema de procesamiento de imágenes. *Tsinghua Sci Technol [Internet].* febrero de 2017; 22(01):112–8. Disponible en: <http://ieeexplore.ieee.org/document/7830901/>
13. Banerjee A, Burlina P, Diehl C. Un método de vector de soporte para la detección de anomalías en imágenes hiperespectrales. *IEEE Trans Geosci Remote Sens [Internet].* Agosto de 2006; 44(8):2282–91. Disponible en: <http://ieeexplore.ieee.org/document/1661816/>
14. Bannari A, Pacheco A, Staenz K, McNairn H, Omari K. Estimación y mapeo de la cobertura de residuos de cultivos en tierras agrícolas utilizando datos hiperespectrales y IKONOS. *Remote Sens Environ [Internet].* Octubre de 2006; 104(4):447–59. Disponible en: <https://linkinghub.elsevier.com/retrieve/pii/S0034425706002148>
15. Lawrence RL, Wood SD, Sheley RL. Mapeo de plantas invasoras utilizando imágenes hiperespectrales y clasificaciones de Breiman Cutler (randomForest). *Remote Sens Environ [Internet].* febrero de 2006; 100(3):356–62. Disponible en: <https://linkinghub.elsevier.com/retrieve/pii/S0034425705003792>
16. Soto Bohorquez JC, Ruiz Reyes JM, Ipanaque Alama W, Chinguel Alama C. Nuevo índice hiperespectral para la determinación del estado de fermentación en el análisis no destructivo para cacao violeta orgánico. *IEEE Lat Am Trans [Internet].* septiembre de 2018; 16(9):2435–40. Disponible en: <https://ieeexplore.ieee.org/document/8789565/>
17. Kokaly RF, Hoefen TM, Graham GE, Kelley KD, Johnson MR, Hubbard BE, et al. Información mineral a escalas de micras a kilómetros: datos de espectrómetro de imágenes de laboratorio, campo y teledetección del depósito de pórfido de cobre de Orange Hill, Alaska, EE. UU. En: *Simposio Internacional de Geociencias y Teledetección IEEE 2016 (IGARSS) [Internet].* IEEE; 2016. Págs. 5418-21. Disponible en: <http://ieeexplore.ieee.org/document/7730411/>

18. Fickus M, Lewis ME, Mixon DG, Peterson J. Imágenes hiperespectrales compresivas para espectroscopia estelar. *Letra de proceso de señal IEEE* [Internet]. Noviembre de 2015; 22(11):1829–33. Disponible en: <http://ieeexplore.ieee.org/document/7115943/>
19. Della Porta CJ, Chang C-I. Procesamiento progresivo de bandas con detección compresiva para la clasificación hiperespectral. *IEEE Trans Geosci Remote Sens* [Internet]. marzo de 2021; 59(3):2378–90. Disponible en: <https://ieeexplore.ieee.org/document/9123599/>
20. Fen Chen, Ting Feng Tang, Ke Wang. Modelo de descomposición de bajo rango para la identificación adaptativa de píxeles vecinos similares en imágenes hiperespectrales. *IEEE Geosci Remote Sens Lett* [Internet]. febrero de 2016; 13(2):172–6. Disponible en: <http://ieeexplore.ieee.org/document/7360895/>
21. Wu Z, Shi L, Li J, Wang Q, Sun L, Wei Z, et al. Implementación paralela de GPU de la clasificación de imágenes hiperespectrales espacialmente adaptativa. *IEEE J Sel Top Appl Earth Obs Remote Sens* [Internet]. abril de 2018; 11(4):1131–43. Disponible en: <https://ieeexplore.ieee.org/document/8066284/>
22. Krug LA, Platt T, Sathyendranath S, Barbosa AB. Estrategias de partición de la superficie oceánica mediante teledetección del color del océano: una revisión. *Prog Oceanogr*. junio de 2017; 155:41–53.
23. Rani M, Masroor M, Kumar P. Teledetección del medio ambiente oceánico y costero – Visión general. En: *Teledetección de Ambientes Oceánicos y Costeros*. Elsevier; 2021. págs. 1-15.
24. Wetherley EB, Roberts DA, Tague CL, Jones C, Quattrochi DA, McFadden JP. Modelización de la teledetección y el balance energético de la variabilidad del clima urbano en una megaciudad semiárida. *Clim Urbano*. Enero de 2021;35:100757.
25. Ganci G, Cappello A, Bilotta G, Del Negro C. Cómo la variedad de datos de teledetección satelital sobre volcanes puede ayudar a los esfuerzos de monitoreo de peligros: La erupción del volcán Nabro en 2011. *Entorno de sensores remotos*. Enero de 2020;236:111426.
26. Fu X, Yao L, Xu W, Wang Y, Sun S. Explorando el efecto de isla de calor urbano de superficie multitemporal y su relación impulsora en la aglomeración urbana Beijing-Tianjin-Hebei. *Appl Geogr*. Julio de 2022;144:102714.
27. Chanchí Golondrino GE, Ospina Alarcón MA, Saba M. Identificación de vegetación en imágenes hiperespectrales utilizando métricas de distancia/correlación. *Atmosphere (Basilea)* [Internet]. 14 de julio de 2023; 14(7):1148. Disponible en: <https://www.mdpi.com/2073-4433/14/7/1148>
28. Saha D, Manickavasagan A. Técnicas de aprendizaje automático para el análisis de imágenes hiperespectrales para determinar la calidad de los productos alimenticios: una revisión. *Curr Res Food Sci*. 2021; 4:28–44.
29. Spilsbury MJ, Euceda A. Transformada Rápida de Fourier. *Rev la Esc Física*. 2016; 4(2):45–52.
30. Chanchí-Golondrino G-E, Ospina-Alarcón M-A, Saba M. Enfoque de análisis de Fourier para identificar cuerpos de agua a través de imágenes hiperespectrales. *Rev Fac ing* [Internet]. 2023; 33(67):E17232. Disponible en: <https://revistas.uptc.edu.co/index.php/ingenieria/article/view/17232>