

Detección y clasificación de objetos camuflados en el espectro visible utilizando cámaras hiperespectrales embarcadas

Delgado Fernández, Alba ¹, Blázquez García, Rodrigo ¹ y Burgos García, Mateo ^{1,*}.

¹ Observatorio Horizontes en Defensa y Seguridad ISDEFE-UPM. Av. Complutense, 30. 28040 Madrid. Correos electrónicos: alba.delgado.fernandez@alumnos.upm.es (ADF), rodrigo.blazquez@upm.es (RBG), mateo@gmr.ssr.upm.es (MBG)

* Autor Principal y responsable del trabajo; Correo electrónico: mateo@gmr.ssr.upm.es (MBG)

Resumen: Entre las líneas de trabajo del Observatorio Horizonte en Defensa y Seguridad ISDEFE-UPM se encuentra el análisis de tecnologías de sensores embarcados con aplicaciones emergentes en sistemas ISTAR (Intelligence, Surveillance, Target Acquisition and Reconnaissance). En esta comunicación, se realiza un estudio de la viabilidad técnica de los sensores hiperespectrales embarcados en plataformas aéreas o satelitales para la detección y clasificación de objetos camuflados. Las imágenes hiperespectrales contienen la respuesta espectral de cada píxel para múltiples bandas del rango visible e infrarrojo. De esta forma, su procesado permite potencialmente la detección y clasificación de objetos camuflados al ojo humano gracias a las diferentes respuestas espectrales que presentan los materiales al considerar también múltiples bandas en el infrarrojo. Para evaluar dichas capacidades, se ha propuesto una cadena de procesado con una carga computacional asumible basada en: (1) algoritmo PCA (*Principal Component Analysis*) para reducir la dimensionalidad de los datos; (2) segmentación mediante el algoritmo *Mean-shift*; (3) detección de las anomalías utilizando el algoritmo *Reed-Xiaoli* (RX), y (4) clasificación mediante *sparse regression*. Se ha analizado el desempeño de esta cadena de procesado utilizando imágenes hiperespectrales sintéticas generadas a partir de firmas espectrales de bases de datos, incluyendo efectos que degradan la calidad de la imagen como: ruido de adquisición, mezcla de firmas espectrales o variaciones aleatorias de las firmas de cada material. Además, se han procesado imágenes hiperespectrales reales de los sensores AVIRIS y HYDICE y multispectrales del satélite Sentinel-2. Los resultados ponen de manifiesto la necesidad de mejorar la robustez del algoritmo de clasificación frente a mezclas de firmas y a variaciones respecto de la base de datos, pero muestran el potencial de esta tecnología en aplicaciones de teledetección.

Palabras clave: Clasificación, detección de anomalías, firma hiperespectral, Reed-Xiaoli.

1. Introducción

Actualmente existe la necesidad de detectar la presencia de objetos, personas o cualquier tipo de material camuflado, no visible al ojo humano, que pudieran indicar el desarrollo de actividades ilícitas. Las infraestructuras utilizadas en actividades ilegales como el tráfico de drogas o de personas son frecuentemente camufladas utilizando materiales plásticos visualmente similares al entorno, por lo que su detección utilizando cámaras de espectro visible embarcadas en plataformas aéreas o satelitales es poco efectiva. Por este motivo, como el camuflaje óptico suele limitarse al espectro visible, para abordar la detección y clasificación de estos objetos, se propone el uso de la tecnología hiperespectral, que permite medir la reflectividad espectral de los materiales presentes en cada píxel de la imagen para un gran número de bandas contiguas que se extienden en el espectro visible e infrarrojo [1]. De esta forma, al presentar cada material una curva de reflectividad característica, denominada firma espectral, se puede clasificar cada objeto y determinar si se trata de un posible indicio de actividades ilícitas.

Además de sus aplicaciones en el ámbito de la defensa y seguridad, la tecnología hiperespectral presenta también múltiples aplicaciones civiles y de interés científico (agricultura, calidad y seguridad de los alimentos, exámenes forenses de documentos, ...) [2]. Por este motivo, dado el elevado potencial de esta tecnología, el objetivo de esta comunicación es evaluar las capacidades de los sensores hiperespectrales embarcados en plataformas aéreas o satelitales en la detección de objetos camuflados.

Para ello, se propone una cadena de procesado de imágenes hiperespectrales que lleva a cabo la detección y clasificación de anomalías (píxeles cuya firma espectral difiere de la del fondo de la imagen), describiendo los diferentes algoritmos empleados para reducir la dimensionalidad de los datos, segmentar las imágenes y realizar dicha detección y clasificación. Posteriormente, para analizar la robustez de los algoritmos, se evalúa su funcionamiento utilizando imágenes hiperespectrales generadas sintéticamente, incluyendo distintos efectos que degradan su calidad (ruido de adquisición, variación aleatoria de las firmas espectrales y mezcla de firmas espectrales). Por último, se comentarán los resultados del procesado de imágenes hiperespectrales y multiespectrales reales.

2. Descripción cadena de procesado evaluada

Como se observa en la Figura 1, el proceso completo incluye una etapa de adquisición de datos utilizando sensores hiperespectrales, en la que se genera la imagen hiperespectral (HSI) (Figura 2) llevando a cabo correcciones atmosféricas y filtrado de ruido, y una etapa de procesamiento, cuyo objetivo es detectar y clasificar los blancos en la imagen. Este artículo se centra en el procesado del cubo hiperespectral, asumiendo que los operadores de los sensores proporcionan la imagen ya corregida y filtrada.

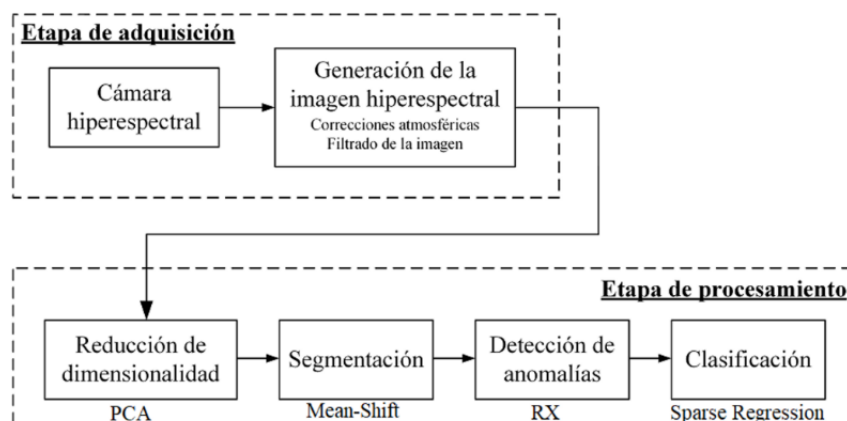


Figura 1: Esquema del proceso de adquisición y procesado de imágenes hiperespectrales.




Figura 2: Cubo de datos hiperespectrales en el que cada píxel de la imagen contiene la reflectividad espectral medida.

En base a la cadena de procesada propuesta, se propone llevar a cabo un preprocesamiento de los datos para segmentar la imagen dividiéndola en regiones de características espectrales similares. Para ello se aplicarán algoritmos de selección de características (*Feature Selection* [3]), para reducir la dimensionalidad inicial del problema, y algoritmos de clustering para agrupar los píxeles por zonas [4]. Una vez segmentada la imagen, se lleva a cabo la detección de posibles objetos ocultos o blancos de interés. Por último, tras detectar las posibles anomalías presentes en la imagen, se propone aplicar una última etapa de clasificación, para minimizar las falsas alarmas del sistema al considerar únicamente los materiales de interés que pueden ser indicios del desarrollo de actividades ilícitas.

2.1. Reducción de dimensionalidad y segmentación de la imagen

Para llevar a cabo la reducción de dimensionalidad del cubo hiperespectral se emplea el algoritmo PCA (*Principal Component Analysis*) [5], el cual realiza una transformación ortogonal convirtiendo las observaciones de un conjunto de variables originales en un conjunto de variables linealmente independientes, denominadas componentes principales, y ordenadas de mayor a menor varianza. De esta forma, los datos originales pueden aproximarse mediante la proyección sobre el subespacio de dimensión reducida generado por los primeros componentes principales (PC). Al aumentar el número de PCs considerados se reduce el error de aproximación a costa de aumentar la dimensionalidad, por este motivo, en la cadena de procesado implementada se han considerado los tres primeros PCs.

A continuación, sobre los datos de dimensión reducida, se aplica el algoritmo de clustering *Mean-Shift* [6] para realizar una agrupación de los datos obtenidos con PCA. Este algoritmo se basa en el uso de ventanas deslizantes que se actualizan y convergen hacia áreas con más densidad de puntos.

2.2. Detección de anomalías

Cuando se emplean imágenes hiperespectrales para la detección de blancos, generalmente, no se dispone de información a priori de las características espectrales de los objetos de interés. En estos casos, los algoritmos de detección utilizados deben identificar las anomalías presentes en la imagen, determinando si los píxeles presentan una diferencia significativa respecto de los píxeles del fondo. El algoritmo Reed-Xiaoli (RX) [7,8] es un detector de anomalías adaptativo con características CFAR (*Constant False Alarm Rate*) que se basa en el GLRT (*Generalized- Likelihood Ratio Test*). Este algoritmo determina la distancia de Mahalanobis entre la observación x y el conjunto de datos del fondo determinado por la media y la matriz de covarianza, y declara la detección de una anomalía si dicha distancia supera un determinado umbral η que fija la probabilidad de falsa alarma del algoritmo:

$$RX(x) = (x - \hat{\mu})^T \left(\frac{N}{N+1} \hat{\Gamma}_x + \frac{1}{N+1} (x - \hat{\mu})(x - \hat{\mu})^T \right)^{-1} (x - \hat{\mu}) \underset{H_0}{\overset{H_1}{\geq}} \eta \quad (1)$$

donde la matriz de covarianza ($\hat{\Gamma}_x$) y firma espectral media ($\hat{\mu}$) se estiman considerando todos los píxeles agrupados en cada conjunto obtenido mediante el algoritmo *mean-shift*, y N es el número de píxeles de referencia.

2.3. Clasificación

Esta última etapa se realiza mediante algoritmos basados en *sparse regresión* [9,10] teniendo en cuenta la limitada resolución espacial de los sensores hiperespectrales, que da lugar, generalmente, a una mezcla de las firmas espectrales de los distintos materiales que componen cada píxel. Este algoritmo se basa en un modelo de mezcla lineal [11], el cual asume que la curva espectral medida para un píxel es una combinación lineal de las firmas espectrales de componentes. A partir de este modelo se puede llevar a cabo un algoritmo de desmezclado (*unmixing*) basado en técnicas *sparse regression* para encontrar el subconjunto óptimo de firmas espectrales de una base de datos que mejor modela la curva espectral medida de cada píxel.

3. Resultados

3.1. Resultados obtenidos en imágenes sintéticas

Para evaluar el funcionamiento y la robustez de la cadena de procesado implementada sobre imágenes sintéticas, se han generado distintos cubos hiperespectrales con zonas de distintos materiales a partir de firmas espectrales obtenidas de la base de datos USGS [12], que presentan diferentes efectos que degradan la calidad de la imagen y que se dan habitualmente en las imágenes reales (variaciones respecto a las firmas contenidas en la base de datos, mezcla de firmas espectrales y ruido del sensor).

Para generar las imágenes sintéticas, se han seleccionado las firmas espectrales de cinco materiales (hierba, pino, arena, asfalto y plástico) (Figura 2^a). La firma espectral del material plástico camuflado, que representa la anomalía que debe ser detectada, se considera igual a la firma de la hierba en el espectro visible. A partir de estas firmas se han generado imágenes espectrales de 100x100 píxeles y 100 bandas espectrales uniformemente distribuidas en el rango de 0.35 μm a 2.4 μm . En la Figura 2b, se presenta la imagen para la banda 50 (1.36 μm) en escala de niveles de reflectividad y la transformación del cubo hiperespectral a RGB (*red, green, blue*) de la imagen hiperespectral sintética que incluye variación de firmas hiperespectrales, ruido de sensor y mezcla en los bordes de las zonas.

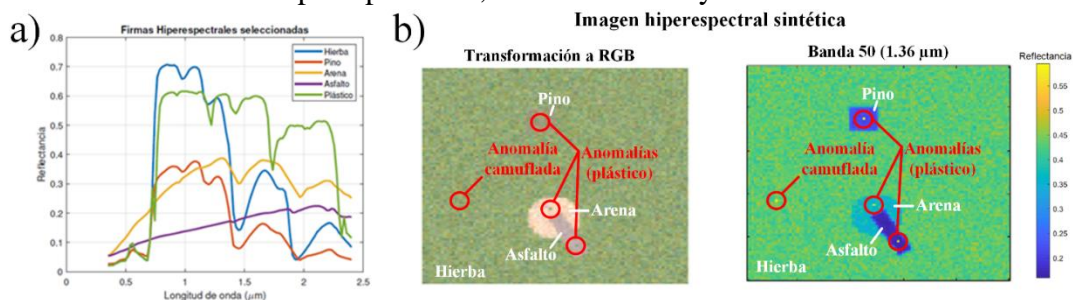


Figura 3: Generación de imágenes hiperespectrales sintéticas: a) Firmas hiperespectrales de los materiales seleccionados; b) Transformación a RGB e imagen de niveles de reflectividad en la banda 50 para el cubo hiperespectral sintético con ruido de sensor (SNR = 25 dB), mezcla de firmas y variaciones respecto a la base de datos.

A continuación, para las imágenes sintéticas con mezcla de firmas espectrales en los bordes de las zonas y ruido de sensor (SNR = 25 dB) (Figura 4a) y con firmas espectrales variadas respecto de la base de datos y ruido de sensor (SNR = 25 dB) (Figura 4b), se representan los resultados obtenidos tras aplicar PCA y la segmentación sobre la nube de puntos realizada con el algoritmo *mean-shift*,

observando que la agrupación en cuatro materiales principales se realiza de forma adecuada, y la detección de las anomalías utilizando el algoritmo RX.

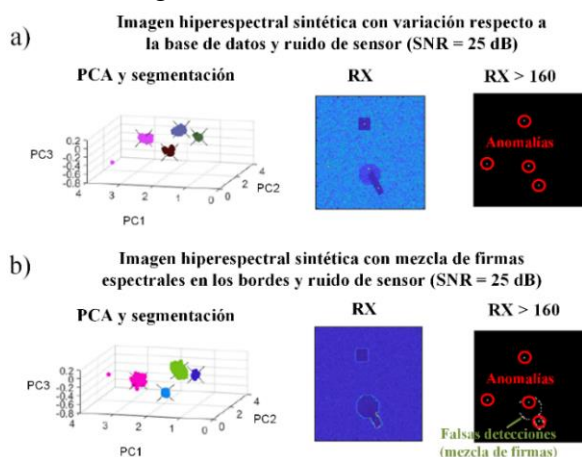


Figura 4: Resultados de PCA, *mean-shift* (cada color representa un grupo obtenido) y RX para imágenes hiperespectrales con ruido de sensor (SNR = 25 dB) y: a) variación respecto de la base de datos; b) mezcla de firmas.

Analizando los resultados de la Figura 4a, se observa que, para la imagen con variación de firmas y ruido de sensor, se detectan adecuadamente las anomalías. Sin embargo, en la Figura 4b, se observa que la mezcla de firmas espectrales en los bordes de las zonas da lugar a detecciones que constituyen falsas alarmas. Por este motivo, como en las imágenes reales se espera que se produzcan mezclas de firmas espectrales debido a la limitada resolución de los sensores, se ha propuesto realizar un desmezclado en los píxeles con detección para determinar qué materiales componen dichas anomalías y considerar únicamente aquellas que contienen materiales que sean indicios de actividades ilícitas.

Por último, para comprobar la robustez del algoritmo de desmezclado y clasificación basado en *sparse regression*, se ha probado a clasificar firmas hiperespectrales en píxeles puros y con mezcla y se ha medido la variación de la abundancia detectada para un píxel de material “hierba” en función de la SNR de la imagen. Como puede observarse en la Figura 5a, que representa las abundancias obtenidas de distintos materiales en el píxel puro de “plástico”, la anomalía compuesta por material “plástico” es clasificada correctamente, aunque no se obtiene una abundancia del 100% debido a la similitud entre las distintas firmas contenidas en la base de datos y al ruido de sensor. A su vez, en la Figura 5b, se observa que en el píxel mezcla se clasifican los dos materiales de la mezcla (“arena” y “hierba”), pero que aparecen además otros materiales erróneos con menor abundancia que podrían llevar a confusión. Para determinar la robustez frente a ruido, la Figura 5c representa la abundancia de “hierba” obtenida para un píxel de “hierba” en función de la SNR de la imagen, comprobando que se requieren SNR altas (superiores a 40 dB). Sin embargo, esta especificación es común en sensores hiperespectrales.




Figura 5: Algoritmo de desmezclado y clasificación de firmas espectrales: a) Desmezclado de un píxel de “plástico” puro; b) Desmezclado de un píxel mezcla de “arena” y “hierba”; c) Variación de la abundancia obtenida de “hierba” en función de la SNR para un píxel de “hierba”.

3.2. Resultados obtenidos en imágenes reales

En este apartado, se aplica la cadena de procesado a imágenes hiperespectrales obtenidas de un dataset de imágenes de los sensores AVIRIS y HYDICE [13], y a imágenes multispectrales obtenidas del satélite Sentinel-2.

a. Procesamiento de imágenes hiperespectrales del sensor AVIRIS y HYDICE

Como se ha descrito anteriormente, en primer lugar, se lleva a cabo la segmentación de las imágenes utilizando *mean-shift* tras haber reducido la dimensionalidad de los datos mediante PCA, ya que las imágenes procesadas presentan, en este caso, más de 200 bandas, mostrando los resultados obtenidos en la Figura 6 para dos conjuntos de datos. Como puede observarse, las imágenes hiperespectrales reales dan lugar a nubes de puntos más difícilmente separables debido a su mayor complejidad. Sin embargo, el algoritmo de segmentación utilizado permite dividir las imágenes en zonas aproximadamente homogéneas. A su vez, también se representan las detecciones obtenidas con el algoritmo RX junto con los umbrales fijados, que permiten detectar bastantes anomalías correspondientes a elementos de la escena que no corresponden con el fondo, como aviones o barcos. Por último, se observa la clasificación del material más abundante presente en cada anomalía, aunque los resultados de esta etapa no son completamente satisfactorios y debe mejorarse la robustez del algoritmo para imágenes reales, posiblemente limitando el número de materiales que componen la base de datos considerando únicamente materiales característicos de distintos tipos (metal, mineral, plantas, agua, plásticos, etc.).

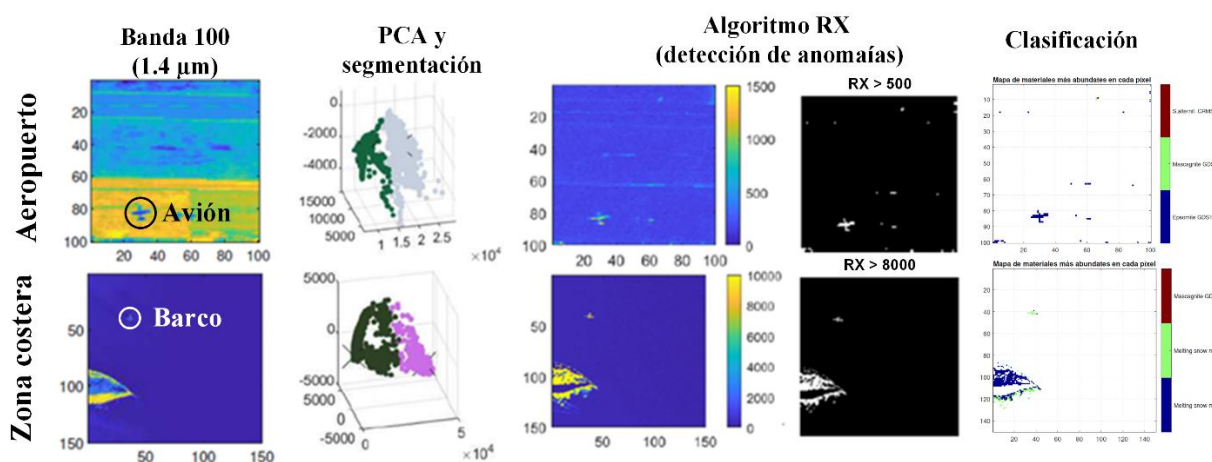


Figura 6: Resultados del procesamiento de imágenes hiperespectrales de los sensores AVIRIS y HYDICE [13], que contienen elementos como barcos o aviones.

b. Procesamiento de imágenes multispectrales Sentinel-2

A continuación, se presentan los resultados obtenidos al aplicar el procesamiento a una imagen multispectral tomada con el satélite Sentinel-2 con 13 bandas espectrales [14]. Se ha escogido una zona que presenta elementos como placas solares que pueden ser considerados anomalías. En la Figura 7, se representan los resultados obtenidos en las distintas etapas del procesado de la imagen. Como puede observarse, la segmentación de la imagen se realiza adecuadamente en cuatro zonas con propiedades espectrales similares (zona amarilla correspondiente a lagos, zona roja correspondiente a áreas boscosas o con vegetación verde, zona azul correspondiente a cultivos de secano y zona verde correspondiente principalmente a infraestructuras como placas solares o carreteras). A su vez, el algoritmo de detección da lugar a anomalías principalmente correspondientes con elementos relacionados con dichas infraestructuras (placas solares, edificios y carreteras), cuya detección puede

resultar de interés, aunque, además, se observan algunas anomalías no deseadas, especialmente en los bordes de las algunas zonas como los lagos o las zonas de cultivo. Aunque los resultados de la clasificación no son del todo satisfactorios, ya que no se obtiene correctamente el material que compone cada anomalía, pueden dar una idea del tipo de material (mineral, vegetación, agua, etc.).

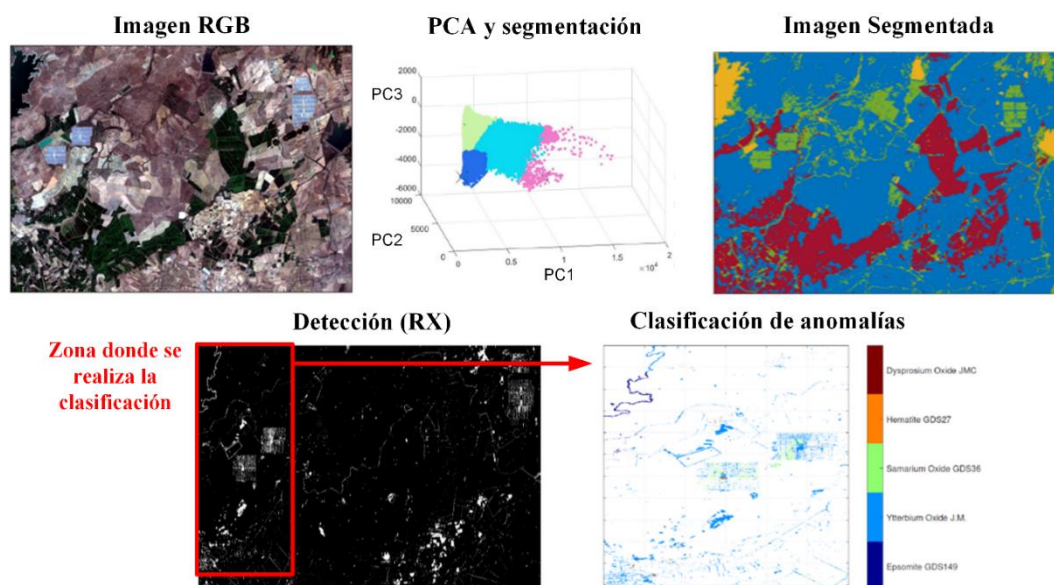


Figura 7: Resultados del procesamiento de una imagen multispectral del satélite Sentinel-2 [14].

Lógicamente, el menor número de bandas de los sensores multispectrales da lugar a un menor desempeño de los algoritmos de detección y clasificación de anomalías, aunque superior a los sensores que cubren únicamente el espectro visible. Sin embargo, los resultados obtenidos muestran el potencial de estos sensores embarcados en plataformas satelitales en aplicaciones de inteligencia, al presentar una cobertura global (generalmente con órbita heliosíncrona), pudiendo aplicar algoritmos de detección de cambios (*change detection*) considerando las imágenes capturadas en múltiples pasadas.

4. Conclusiones

Las imágenes hiperespectrales permiten obtener curvas muy detalladas del comportamiento espectral de objetos, gracias al número de bandas que recoge el sensor. Se trata de una tecnología emergente en las áreas de seguridad y defensa, con cada vez un mayor número de aplicaciones. Entre estas aplicaciones, dentro del campo de la teledetección, destaca la posibilidad de detectar objetos camuflados ópticamente al ojo humano utilizando imágenes hiperespectrales. En esta comunicación, se ha propuesto una cadena de procesamiento de imágenes hiperespectrales para la detección y clasificación de anomalías.

Para ello, la cadena propuesta realiza en primer lugar una reducción de la dimensionalidad de los datos utilizando el algoritmo PCA, con el objetivo de reducir la carga computacional al observar que los tres primeros componentes principales contienen la mayor parte de la información y permiten separar materiales con distintas respuestas espectrales. Posteriormente, se realiza una segmentación de la imagen hiperespectral mediante el algoritmo *mean-shift* aplicado a los datos transformados sobre los tres primeros componentes principales. En esta etapa, se ha observado que no siempre es adecuado segmentar la imagen en un mayor número de clústers, ya que la sobresegmentación puede afectar a la detección posterior de las anomalías en la imagen y producir su ocultamiento.

Tras realizar la segmentación, se lleva a cabo la detección y posterior clasificación de las anomalías. Para ello se ha utilizado el algoritmo RX empleando los conjuntos obtenidos en la etapa de

segmentación para calcular una media y matriz de covarianza de cada conjunto. Por último, la clasificación de las anomalías detectadas se lleva a cabo mediante un algoritmo basado en *sparse regression*. Se observó que, en imágenes con poco ruido, el clasificador funciona correctamente, pero con SNR reducidas, el clasificador no presenta un funcionamiento adecuado, poniendo de manifiesto la dificultad de la clasificación de los materiales, especialmente en situaciones con ruido, mezcla de firmas espectrales o variaciones de las firmas espectrales respecto de las contenidas en la base de datos.

Por tanto, se concluye que los algoritmos implementados (PCA, Mean-shift y RX) permiten la detección de anomalías, pero que los algoritmos de clasificación deben mejorarse para realizar una clasificación adecuada de los materiales que permita reducir el número de falsas alarmas del algoritmo producidas por ruido o por mezcla de firmas espectrales, al eliminar aquellas detecciones que no correspondan con los materiales de interés.

Aunque, los resultados obtenidos muestran el potencial de la tecnología hiperespectral, existen actualmente limitaciones que deben ser estudiadas para obtener sistemas operativos, especialmente relacionadas con la carga computacional y la adquisición y procesado de la imagen en tiempo real, y de coste asumible.

Referencias

- [1] Manolakis D, Marden D, Shaw G: Hyperspectral image processing for automatic target detection applications. *Lincoln Lab. J.* **2013**;14(1): 79-116.
- [2] Khan MJ, Khan HS, Yousaf A, Khurshid K, Abbas A: Modern Trends in Hyperspectral Image Analysis: A Review. *IEEE Access.* **2018**;6:14118-14129.
- [3] Jia X, Kuo BC, Crawford MM: Feature mining for hyperspectral image classification. *Proc. IEEE.* **2013**;101(3):676-697.
- [4] Cisz A, Schott J: Performance comparison of hyperspectral target detection algorithms. *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery.* **2006**:839-849.
- [5] Ng A: Principal Component Analysis (CS229 Lecture Notes), 2017 [En línea]. Disponible en: <http://cs229.stanford.edu/notes/cs229-notes10.pdf> [Accedido: 05/09/2019].
- [6] Cheng Y: Mean shift, mode seeking, and clustering. *IEEE Trans. Pattern Anal. Mach. Intell.* **1995**;17(8):790-799.
- [7] Matteoli S, Diani M, Corsini G: A tutorial overview of anomaly detection in hyperspectral images. *IEEE Aerosp. Electron. Syst. Mag.* **2010**;25(2):5-27.
- [8] Stein DWJ, Beaven SG, Hoff LE, Winter EM, Schaum AP, Stocker AD: Anomaly detection from hyperspectral imagery. *IEEE Signal Process. Mag.* **2002**;19(1):58-69.
- [9] Bioucas-Dias JM et al.: Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression-based approaches. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2012**;5(2):354-379.
- [10] Li F, Zhang P, Lu H: An Improved Unsupervised Band Selection of Hyperspectral Images Based on Sparse Representation. *Stud. Comput. Intell.* **2018**;810:135-145.
- [11] Bioucas-Dias JM, Plaza A, Camps-Valls G, Scheunders P, Nasrabadi NM, Chanussot J: Hyperspectral remote sensing data analysis and future challenges. *IEEE Geosci. Remote Sens. Mag.* **2013**;1(2):6-36.
- [12] Spectral Lab, USGS [En línea]. Disponible en: <https://www.usgs.gov/labs/spec-lab> [Accedido: 05/09/2019].
- [13] Kang X: Hyperspectral Data Sets [En línea]. Disponible en: <http://xudongkang.weebly.com/data-sets.html> [Accedido: 05/09/2019].
- [14] ESA, Sentinel Data [En línea]. Disponible en: <https://scihub.copernicus.eu/dhus/#/home> [Accedido: 05/09/2019].