

UNIVERSIDAD POLITÉCNICA DE MADRID

**ESCUELA TÉCNICA SUPERIOR DE INGENIEROS DE
TELECOMUNICACIÓN**



**GRADO EN INGENIERÍA DE TECNOLOGÍAS Y SERVICIOS DE
TELECOMUNICACIÓN**

**DESARROLLO DE ALGORITMOS PARA LA DETECCIÓN DE OBJETOS
ÓPTICAMENTE CAMUFLADOS UTILIZANDO CÁMARAS
HIPERESPECTRALES EMBARCADAS**

**ALBA DELGADO FERNÁNDEZ
JUNIO 2019**

TRABAJO FIN DE GRADO

Título: Desarrollo de algoritmos para la detección de objetos ópticamente camuflados utilizando cámaras hiperespectrales embarcadas
Autor: Alba Delgado Fernández
Tutor: Rodrigo Blázquez García
Departamento: Señales, Sistemas y Radiofrecuencia

Tribunal:

Presidente:

Vocal:

Secretario:

Suplente:

Fecha de lectura:

Calificación:

Resumen

Los sensores hiperespectrales son una tecnología con aplicaciones emergentes en el ámbito de la defensa y la seguridad. Las imágenes adquiridas por estos sensores contienen información espectral de cada píxel en múltiples bandas, generalmente más de 100, del rango visible e infrarrojo. De esta forma, las imágenes hiperespectrales permiten la detección potencial de objetos camuflados en el espectro visible gracias a las diferentes respuestas espectrales de los materiales en otras bandas. Por este motivo, el objetivo principal de este trabajo es el desarrollo y evaluación del funcionamiento de una cadena de procesamiento de imágenes hiperespectrales que permita la detección y clasificación de objetos ocultos que puedan ser indicios de actividades ilícitas. El trabajo realizado se enmarca dentro de las líneas de investigación en sistemas ISTAR (*Intelligence, Surveillance, Target Acquisition and Reconnaissance*), que son combinaciones de sensores y plataformas que proporcionan información avanzada de inteligencia.

En la primera parte del trabajo, se lleva a cabo un estudio teórico sobre el funcionamiento de los sensores hiperespectrales, analizando sus principales características, las ventajas e inconvenientes de esta tecnología, sus principales aplicaciones y las plataformas en las que van embarcados. Por otro parte, se estudian los diferentes algoritmos que forman parte de la cadena de procesamiento propuesta para la detección y clasificación de objetos ocultos. Esta cadena de procesamiento realiza un preprocesamiento de los datos para reducir su dimensionalidad mediante el algoritmo PCA (*Principal Component Analysis*) y segmentar la imagen en regiones de características similares utilizando el algoritmo *Mean-shift*. Posteriormente, se lleva a cabo la detección de las anomalías mediante el algoritmo Reed-Xiaoli (RX) y su clasificación utilizando una base de datos de firmas espectrales de distintos materiales y algoritmos basados en *sparse regression*.

Tras implementar la cadena de procesamiento completa en MATLAB, se ha evaluado su funcionamiento utilizando imágenes hiperespectrales sintéticas con anomalías generadas a partir de las firmas espectrales de cinco materiales (hierba, pino arena y asfalto como fondo de la imagen, y plástico como anomalía) obtenidas de la librería espectral USGS. Para ello, se han incluido, además, distintos efectos que degradan la calidad de la imagen hiperespectral ideal: ruido de adquisición para distintos niveles de SNRs (*Signal-to-Noise Ratio*), variaciones aleatorias de las firmas espectrales respecto de la firma contenida en la base de datos y mezcla de las firmas espectrales en los bordes de las zonas de cada material.

Finalmente, se han procesado imágenes hiperespectrales y multispectrales obtenidas de bases de datos públicas de los sensores AVIRIS y HYDICE y del satélite Sentinel-2, para comprobar el funcionamiento y las limitaciones de la cadena de procesamiento propuesta en imágenes reales con anomalías.

Los resultados obtenidos ponen de manifiesto el gran potencial de la tecnología hiperespectral para la detección y clasificación de objetos ocultos y otros blancos de interés en relación a las cámaras de espectro visible o de infrarrojos.

Palabras clave: Algoritmo Reed-Xiaoli, clasificación, detección de anomalías, firma espectral, hiperespectral, MATLAB, Mean-shift, PCA, regresión dispersa.

Abstract

Hyperspectral sensors are an emerging technology in security and defence applications. The images acquired by these sensors have spectral information of each pixel in several bands, generally more than 100, along the visible and infrared ranges. In this way, hyperspectral images allow to potentially detect camouflaged objects in the visible spectrum, thanks to the spectral differences in other bands. For this reason, the main objective of this project is the development and assessment of a processing chain to detect and classify in hyperspectral images camouflaged objects, which may be evidence of illicit activities. This project is related to the current research topics on ISTAR (Intelligence, Surveillance, Target Acquisition and Reconnaissance) systems, which are combinations of sensors and platforms to provide advanced intelligence information.

In the first part of the project, a theoretical study about the operation and basis of hyperspectral sensors has been carried out, analysing their main characteristics, advantages and disadvantages, applications and platforms. Furthermore, the different algorithms which are used in the proposed processing chain for detecting and classifying camouflaged objects are presented. This processing chain performs a data preprocessing to reduce their dimensionality by means of a PCA (Principal Component Analysis) and segment the image in zones with similar spectral characteristics by using the Mean-shift algorithm. Afterwards, the anomalies are detected by the Reed-Xiaoli (RX) algorithm and classified by using a spectral library with the spectral signatures of different materials and sparse regression algorithms.

After implementing the whole processing chain in MATLAB, its performance has been assessed by using synthetic hyperspectral images with anomalies generated with the spectral signatures of five materials (grass, pine, sand and asphalt as image background and plastic as anomaly) obtained from the USGS spectral library. Besides, several degrading effects have been considered to generate these synthetic hyperspectral images: acquisition noise for different SNR (Signal-to-Noise Ratio) levels, random variations of the spectral signatures of the materials with respect to the signature of the spectral library and spectral mixing in the zone borders of each material.

Finally, hyperspectral images, acquired by AVIRIS and HYDICE sensors, and multispectral images, acquired by Sentinel-2 satellite, obtained from public access databases have been processed in order to analyse the performance and limitations of the proposed processing chain in real images with anomalies.

The obtained results show the great potential of hyperspectral technology to detect and classify camouflaged objects and other targets of interest with respect to visible spectrum or infrared cameras.

Keywords: Anomaly detection, classification, hyperspectral, MATLAB, Mean-shift, PCA, Reed-Xiaoli algorithm, sparse regression, spectral signature.

Agradecimientos

Me gustaría dedicar unas líneas para agradecer a todas las personas que han ayudado a que este trabajo saliese adelante.

En primer lugar, dar las gracias a Mateo por haber confiado en mi y darme la oportunidad, y gracias Rodrigo por tus explicaciones, correcciones, consejos y paciencia para explicarme todo.

A todos mis amigos de la universidad, Ana, Peña, Gema, Paula, Isa, Julio y Carlos por haberme ayudado a superar los malos momentos estos cuatro años de carrera y hacerme seguir adelante. A ti Miguel, gracias por haber estado siempre a mi lado estos años, por haberme apoyado en todo, por sacar lo mejor de mí y ayudarme siempre que podías.

Por último, dar las gracias a mi familia. A mi padre Narciso por haber creído siempre en mi y ayudarme a luchar para conseguir todo lo que me propusiese. Y finalmente a mi madre Pilar, tú eras y siempre serás lo mejor de mí, gracias por haberme hecho la persona que soy, por haber sido la mejor madre que podría haber tenido y por haberme dado tu amor sincero y apoyo incondicional, este trabajo te lo dedico a ti.

Índice general

Resumen	I
Abstract	II
1. Introducción	1
1.1. Ventajas e inconvenientes tecnología hiperespectral	2
1.2. Proceso de adquisición y procesado de los datos	4
1.3. Objetivos	6
2. Estado del arte	7
2.1. Fundamentos de la tecnología hiperespectral	7
2.2. Procesamiento de datos hiperespectrales	12
2.2.1. Reducción de dimensionalidad basada en PCA	12
2.2.2. Segmentación de imágenes hiperespectrales	13
2.2.3. Algoritmos para la detección de anomalías	17
2.2.4. Algoritmos para la clasificación de anomalías	18
3. Procesamiento de imágenes sintéticas	21
3.1. Generación cubos hiperespectrales sintéticos	21
3.1.1. Generación de las firmas hiperespectrales	21
3.1.2. Generación de los cubos hiperespectrales	22
3.2. Segmentación de imágenes sintéticas	25
3.2.1. Principal Components Analysis. PCA	25
3.2.2. Mean-Shift	27
3.3. Detección de anomalías en las imágenes sintéticas	30
3.4. Clasificación de anomalías en las imágenes sintéticas	34

4. Procesamiento de imágenes hiperespectrales y multiespectrales reales	38
4.1. Procesamiento de imágenes hiperespectrales del sensor AVIRIS y HYDICE	38
4.1.1. Resultados de la etapa de segmentación	38
4.1.2. Resultados de la etapa de detección de anomalías	39
4.1.3. Clasificación en el dataset	42
4.2. Procesamiento Sentinel	45
4.2.1. Segmentación de la imagen multiespectral	45
4.2.2. Detección de anomalías en la imagen multiespectral	46
4.2.3. Clasificación en Sentinel	47
5. Líneas futuras y conclusiones	49
Bibliografía	51
A. Impactos debidos a este proyecto	54
A.1. Contexto general	54
A.2. Descripción de los impactos posibles	54
A.3. Análisis de impactos más relevantes en el proyecto	55
A.4. Reflexión final	55
B. Presupuesto económico	56
C. Aplicaciones de la tecnología hiperespectral	58
D. Plataformas en las que van embarcadas los sensores	61
D.0.1. Plataformas espaciales	61
D.0.2. Plataformas aéreas:	62

Índice de figuras

1.1. Firmas espectrales de cuatro materiales diferentes (lona verde, lona azul, hierba y asfalto) [11], que demuestran la capacidad potencial de los sensores hiperespectrales de clasificar los materiales en base a las diferentes curvas de reflectancia medidas para cada píxel de la imagen, a pesar de que presenten respuestas similares en la zona visible del espectro.	3
1.2. Esquema del proceso de adquisición y procesado de imágenes hiperespectrales. Este trabajo se centra en el procesado de la imagen hiperespectral, realizando una segmentación de la imagen y la detección y clasificación de las anomalías que pueden indicar el desarrollo de actividades ilícitas.	4
2.1. Espectro electromagnético y transmitancia atmosférica. En las bandas UV, visibles, NIR y SWIR, los espectros son predominantemente reflectivos, mientras que en las bandas MWIR y LWIR predomina la componente de emisividad [23].	8
2.2. Proceso de adquisición de imágenes hiperespectrales [24]. La reflectancia de los materiales puede ser obtenida a partir de la radiancia medida tras un proceso de compensación atmosférica que tenga en cuenta el espectro de la radiación solar y la curva de transmitancia de la atmósfera.	9
2.3. Modos de adquisición de los sensores hiperespectrales [5].	10
2.4. Factores que determinan la resolución espacial de un sensor hiperespectral [27].	11
2.5. Comparación de la resolución espectral en sensores hiperespectrales y multispectrales [28].	11
2.6. Diagrama de las etapas de procesamiento que se seguirán en este trabajo.	12
2.7. Ejemplo de aplicación de PCA sobre una imagen hiperespectral capturada por el sensor AVIRIS.	13
2.8. Algoritmo <i>K-means</i> aplicado sobre una imagen hiperespectral para $k = 3$ y $k = 6$ (cada color corresponde a un clúster).	15
2.9. Ejemplo de inicialización de los centroides (puntos rojos) en el algoritmo <i>Mean-shift</i> (izq.) y de su actualización (puntos amarillos) en la primera iteración hacia zonas con mayor densidad de puntos (dcha.).	16
2.10. Algoritmo <i>Mean-shift</i> aplicado sobre una imagen hiperespectral (cada color corresponde a un clúster).	16
2.11. Ventana de referencia para estimar la media y matriz de covarianza muestrales en una zona localizada alrededor de la celda bajo test.	18

2.12. Modelos de mezcla. a) Mezclado lineal donde el espectro medido es una media ponderada de los espectros de los materiales b) Mezcla no lineal íntima donde los materiales están muy cerca c) Mezcla no lineal con múltiples interacciones entre capas [20]. 19

3.1. Firmas hiperespectrales seleccionadas de la base de datos y las variaciones aleatorias realizadas para formas nuestras imágenes sintéticas. 22

3.2. Matrices de abundancias generadas para los materiales hierba, pino, arena y asfalto. 23

3.3. Cubos hiperespectrales generados a partir de las matrices de abundancias y las firmas espectrales de los materiales considerados para evaluar el funcionamiento de los algoritmos implementados para la detección y clasificación de objetos camuflados. 23

3.4. Reflectancia en la banda 50 (1.36 μm) de la imagen ideal degradada por ruido con los ocho niveles de SNR evaluados. 24

3.5. Resultados del algoritmo PCA aplicado a las imágenes sintéticas generadas. Se representan los datos proyectados sobre las tres primeras componentes principales, separándose en cinco nubes de puntos correspondientes a los cuatro materiales de fondo y a las anomalías, en los que debe segmentarse la imagen con los algoritmos de segmentación. 26

3.6. Resultados obtenidos con algoritmo *K-means* aplicados a los datos hiperespectrales transformados sobre los tres primeros componentes principales (cada color representa un clúster obtenido con el algoritmo). 27

3.7. Resultados del algoritmo *Mean-Shift* aplicado a las imágenes sintéticas generadas (cada color representa un clúster obtenido del algoritmo). 29

3.8. Algoritmo RX aplicado a la imagen con las firmas hiperespectrales variadas y una SNR de 25 dB. 31

3.9. Algoritmo RX aplicado a la imagen con materiales mezclados en los bordes y una SNR de 25 dB 31

3.10. Algoritmo RX aplicado a la imagen con las firmas hiperespectrales variadas, materiales con los bordes mezclados y una SNR de 25 dB. 32

3.11. Reflectancia en la banda 50 (1.36 μm) de las imágenes hiperespectrales sintéticas generadas con SNR = 5 dB y SNR = 30 dB 32

3.12. Resultados del algoritmo *Mean-shift* aplicado sobre dos imágenes sintéticas con SNR = 5 dB y SNR = 30 dB, respectivamente, para comprobar el comportamiento de los algoritmos frente a ruido. 33

3.13. Resultados del algoritmos RX aplicado sobre dos imágenes sintéticas con SNR = 5 dB y SNR = 30 dB, respectivamente, para comprobar el comportamiento de los algoritmos frente a ruido. 33

3.14. Clasificación de los espectros de cuatro píxeles correspondientes a los cuatro materiales de fondo de la imagen ideal: hierba, arena, pino y asfalto. 35

3.15. Clasificación de un píxel de plástico (anomalía introducida) del cubo hiperespectral generado para la imagen ideal.	36
3.16. Clasificación de un píxel escogido en el borde mezclado entre la Arena y la Hierba sin considerar ruido ni variaciones aleatorias de las firmas espectrales respecto a la base de datos.	36
3.17. Abundancia obtenida para un píxel de hierba en función de la SNR de la imagen.	37
3.18. Mapa de abundancias de la imagen ideal hiperespectral completa, con SNR de 50dB.	37
4.1. Corte del cubo hiperespectral del dataset de AVIRIS para evaluar el procesamiento implementado. Las imágenes de la primera fila corresponden a aeropuertos, la segunda fila a playas y la tercera a zonas urbanas.	39
4.2. Resultados del algoritmo <i>Mean-shift</i> aplicado a las imágenes con anomalías de los datasets de AVIRIS y HYDICE (cada color representa un clúster).	40
4.3. Resultado del algoritmo RX con segmentación previa antes de umbralizar aplicado a imágenes hiperespectrales reales.	40
4.4. Resultados umbralizados del algoritmo RX con segmentación previa, en los que se observan las anomalías detectadas.	41
4.5. Resultado del algoritmo RX con ventana de referencia antes de umbralizar aplicado a imágenes hiperespectrales reales.	41
4.6. Resultados umbralizados del algoritmo RX con ventana de referencia, en los que se observan las anomalías detectadas.	42
4.7. Mapas de abundancias de los cuatro materiales más abundantes en las anomalías detectadas del dataset del aeropuerto.	43
4.8. Mapa de materiales más abundantes en cada píxel de anomalía en el dataset del aeropuerto.	43
4.9. Clasificación de los cuatro materiales más abundantes en las anomalías detectadas pertenecientes al dataset de la playa	44
4.10. Mapa de abundancias de las anomalías detectadas en el dataset de la playa	44
4.11. Imagen RGB de la imagen multiespectral seleccionada del Sentinel-2 para evaluar los resultados del procesamiento de una imagen real multiespectral con anomalías (placas solares) [7].	45
4.12. Algoritmo PCA aplicado a la imagen multiespectral del Sentinel-2.	46
4.13. Resultados del algoritmo <i>Mean-shift</i> aplicado a la imagen multiespectral del Sentinel-2 utilizando dos radios distintos de la ventana de asignación (cada color corresponde a un clúster).	46
4.14. Imagen segmentada del Sentinel-2 con el algoritmo <i>Mean-shift</i> para dos valores distintos del radio de la ventana deslizante (cada color corresponde a un clúster).	47

4.15. Resultados del algoritmo RX aplicado a la imagen multiespectral del Sentinel-2 segmentada con <i>Mean-shift</i> utilizando dos radios de la ventana deslizante que dan lugar a segmentaciones en 4 o 7 clústers, respectivamente.	48
4.16. Resultados del algoritmo de clasificación aplicado a una sección de la imagen del Sentinel-2 que contiene una zona con placas solares.	48
D.1. Cámaras Hiperespectrales ofrecidas por la empresa Resonon [43]	63

Glosario

CCD	Charge Coupled Devide
CMOS	Complemetary Metal Oxide Semiconductor
EO	Earth Observing
FS	Feature Selection
FWHM	Full Width at Half Maximum
GLRT	Generalized Likelihood Ratio Test
HSI	Hyperspectral Imagery
ICA	Independent Component Analysis
IFOV	Instantaneous Field-of-View
ISTAR	Intelligence, Surveillance, Target Acquisition and Reconnaissance
LWIR	Long-wavelength infrared
MNF	Minimum Noise Fraction
MSI	MultiSpectral Instrument
MTTF	Mean Time To Failure
MWIR	Medium-wavelength infrared
NIR	Near-infrared
PC	Principal Components
PCA	Principal Component Analysis
PWM	Pulse-Width Modulation
RX	Reed-Xiaoli
SAM	Spectral Angle Mapper
SSRX	Subspace RX
SWIR	Short-wavelength infrared
UAV	Unmanned Aerial Vehicles
USGS	United States Geological Survey

Capítulo 1

Introducción

Este trabajo surge de la necesidad actual de detectar en áreas extensas la presencia de objetos, personas o cualquier tipo de material 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 resulta poco efectiva. Por este motivo, como el camuflaje óptico suele limitarse al espectro visible, para abordar la detección y clasificación de estos objetos camuflados, se propone el uso de la tecnología hiperespectral, que permite medir la reflectancia espectral de los materiales presentes en cada píxel de la imagen para un gran número de bandas espectrales contiguas que se extienden tanto en el espectro visible como en el infrarrojo [1]. De esta forma, al presentar cada material una curva de radiancia característica, denominada firma espectral, se puede clasificar cada objeto detectado y determinar si se trata de un posible indicio de actividades ilícitas.

La tecnología hiperespectral es una tecnología emergente en el ámbito de la defensa y la seguridad y su uso ha crecido en los últimos años, abarcando cada vez un mayor número de aplicaciones [2]. Por este motivo, con el objetivo de evaluar las capacidades de los sensores hiperespectrales en la detección de objetos camuflados ópticamente, este trabajo se enmarca dentro de una de las líneas de investigación definidas por el Observatorio Horizontes en Defensa y Seguridad (Cátedra Isdefe-UPM), en concreto en el ámbito de los sistemas ISTAR (*Intelligence, Surveillance, Target Acquisition and Reconnaissance*). Estos sistemas están formados por plataformas (terrestres, navales, aéreas o satelitales) en las que se embarcan distintos tipos de sensores de radiofrecuencia (guerra electrónica y radar) o sensores ópticos (cámaras EO/IR e hiperespectrales). Estos sensores miden determinados parámetros que, tras ser procesados, aportan información de inteligencia como, por ejemplo, la localización de un determinado objetivo, para el apoyo a la toma de decisiones o a la planificación de misiones en el ámbito de la defensa [3, 4].

La tecnología hiperespectral puede considerarse una tecnología dual, ya que además de sus aplicaciones en el ámbito de la defensa y la seguridad, como la detección y clasificación de blancos ocultos, se han desarrollado múltiples aplicaciones civiles y de interés científico, entre las que destacan las aplicaciones en el ámbito de la agricultura, con el objetivo de mejorar la eficiencia los procesos productivos agrícolas, empleándose para medir determinados índices relacionados con el contenido de clorofila o agua o con ciertas características de los suelos. Además, el uso de esta tecnología está cada vez más extendida en sectores tan variados como la calidad y seguridad de los alimentos, diagnósticos médicos, gestión de recursos hídricos, exámenes forenses de

documentos y autenticación de obras de arte. Aunque este trabajo se centra en la detección de objetos ocultos basándose en algoritmos de detección y clasificación de anomalías, los procesados desarrollados pueden ser adaptados para la detección de otros elementos de interés como, por ejemplo, plásticos o manchas de combustible en la superficie mar, focos de incendios o coches [5].

Tras este primer capítulo de introducción, en el segundo capítulo, se presenta un estudio del estado del arte de la tecnología hiperespectral, analizando sus fundamentos y las principales características y modos de adquisición de los diferentes sensores. Además, se propone una cadena de procesamiento de imágenes hiperespectrales para la detección y clasificación de anomalías y se describen los diferentes algoritmos empleados para reducir la dimensionalidad de los datos, segmentar las imágenes y detectar y clasificar las anomalías. En el tercer capítulo, se evalúa el funcionamiento de la cadena de procesamiento implementada en Matlab 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) para analizar la robustez de los algoritmos. En el cuarto capítulo, se presentan los resultados del procesamiento de imágenes hiperespectrales [6] y multispectrales [7] reales que contienen anomalías. Finalmente, en el quinto capítulo se presentan las conclusiones de este trabajo y posibles líneas futuras..

1.1. Ventajas e inconvenientes tecnología hiperespectral

Los sensores hiperespectrales presentan una elevada resolución espectral tanto en el espectro visible como en el infrarrojo, la cual está relacionada directamente con el número de bandas que pueden adquirir estos sensores ópticos. Gracias a la gran cantidad de bandas estrechas medidas a lo largo del espectro electromagnético, generalmente más de 100 bandas, se obtiene una curva de reflectancia para cada píxel de la imagen que permite distinguir cambios entre unos materiales y otros a pesar de que sean visualmente similares en el espectro visible. Comparándolos con otros tipos de cámaras, como los sensores multispectrales que adquieren entre 10 y 15 bandas, las cámaras RGB con 3 bandas o las cámaras de infrarrojos generalmente de una banda, los sensores hiperespectrales presentan mayor capacidad para realizar clasificaciones detalladas de material o la detección de anomalías gracias a información espectral más detallada que se obtiene de cada píxel de la imagen[5],[8],[9],[10].

La reflectividad de los materiales varía con la longitud de onda de la radiación incidente y cada uno presenta una curva de reflectividad característica conocida como firma espectral. En la Figura 1.1, se representan las firmas espectrales de cuatro materiales (lona plástica verde, lona plástica azul, hierba y asfalto) obtenidas de la biblioteca espectral del USGS (*United States Geological Survey*) [1]. Como puede observarse, las firmas hiperespectrales de las lonas azul y verde son diferentes en el espectro visible (0.4 - 0.7 μm) debido a su diferente color, pero en las zonas NIR (*Near-infrared*, 0.7 - 1.4 μm) e SWIR (*Short-wavelength infrared*, 1.4 - 3 μm) presentan respuestas similares debido a que ambas están fabricadas con el mismo tipo de plástico. Sin embargo, aunque la lona verde y la hierba presentan una banda de reflectividad predominante en el espectro visible en torno a 0.5 - 0.55 μm , característica del color verde, que puede permitir el camuflaje de la lona en una zona de vegetación cuando se consideran imágenes RGB, existe una gran diferencia entre ambas firmas hiperespectrales especialmente en

la banda 1.4 - 2.5 μm que posibilitaría la distinción de ambos materiales en imágenes hiperespectrales. A su vez, la firma espectral del asfalto es completamente diferente a las tres anteriores.

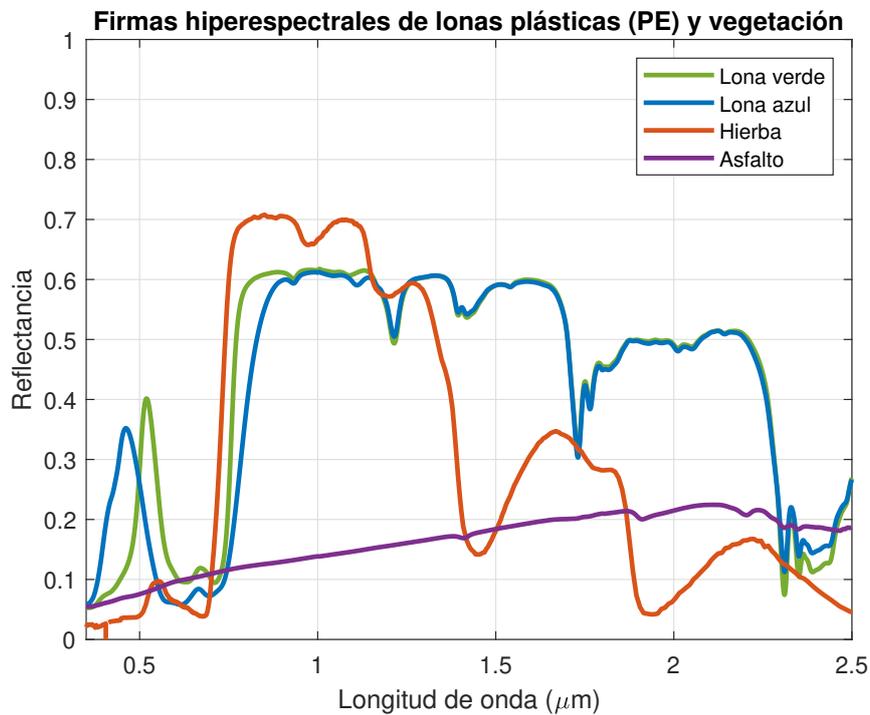


Figura 1.1: Firmas espectrales de cuatro materiales diferentes (lona verde, lona azul, hierba y asfalto) [11], que demuestran la capacidad potencial de los sensores hiperespectrales de clasificar los materiales en base a las diferentes curvas de reflectancia medidas para cada píxel de la imagen, a pesar de que presenten respuestas similares en la zona visible del espectro.

Generalmente, las cámaras hiperespectrales presentan una menor resolución espacial que las cámaras de espectro visible o infrarrojo. Sin embargo, la gran desventaja de estos sensores es la elevada carga computacional que conlleva la generación y el procesado de las imágenes hiperespectrales debido a la elevada resolución espectral. Esta carga computacional limita, actualmente, las aplicaciones en tiempo real de estos sensores y la frecuencia de adquisición de las imágenes, que constituyen requisitos especialmente importantes en sensores embarcados en UAVs. Por este motivo, es importante llevar a cabo una reducción de la dimensionalidad de los datos, consiguiendo obtener una representación mínima de la imagen pero que disponga de la información indispensable para llevar a cabo el análisis deseado o la detección y clasificación de los objetos de interés. Además, los sensores hiperespectrales presentan un coste considerablemente superior a otros tipos de sensores ópticos, aunque existen satélites con sensores hiperespectrales que cubren gran parte de la superficie terrestre y proporcionan acceso público a sus datos [12].

1.2. Proceso de adquisición y procesado de los datos

Como se observa en la Figura 1.2, el proceso de adquisición de datos utilizando sensores hiperespectrales incluye una etapa de generación de la imagen hiperespectral (HSI) en la que se llevan a cabo correcciones atmosféricas y el filtrado de la imagen para la reducción de ruido. A continuación, con el objetivo de detectar y clasificar los blancos en la imagen, se procesa el cubo de datos formado con las bandas medidas que no están afectadas por la absorción de los gases de la atmósfera, especialmente por las moléculas de agua. Este trabajo se centra en el procesado del cubo hiperespectral, asumiendo que los operadores de los sensores proporcionan la imagen ya corregida y filtrada.

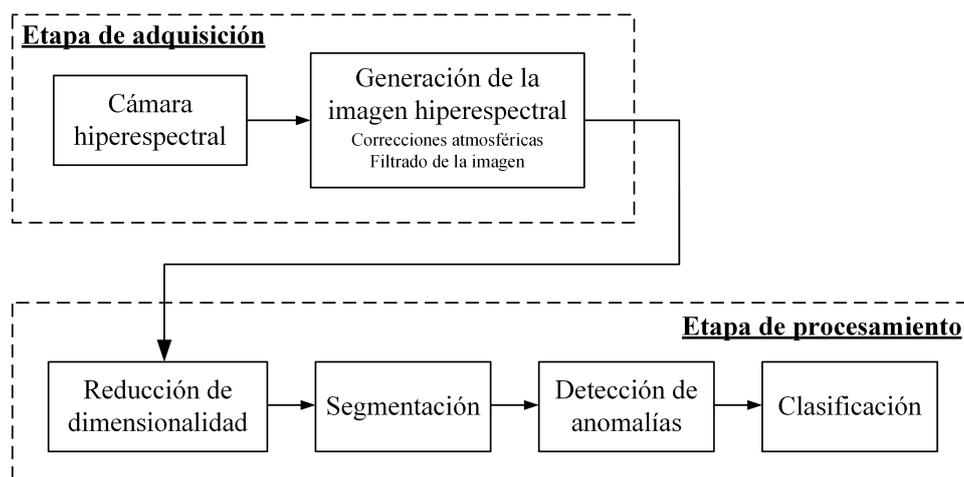


Figura 1.2: Esquema del proceso de adquisición y procesado de imágenes hiperespectrales. Este trabajo se centra en el procesado de la imagen hiperespectral, realizando una segmentación de la imagen y la detección y clasificación de las anomalías que pueden indicar el desarrollo de actividades ilícitas.

En primer lugar, se propone llevar a cabo un preprocesamiento de los datos para segmentar la imagen dividiéndola en regiones de características espectrales similares. Para ello, esta segmentación se basará en algoritmos de selección de características (*Feature selection*, FS), para reducir la dimensionalidad inicial del problema, y en algoritmos de *clustering* para agrupar los píxeles por zonas. Algunos de los algoritmos útiles para esta etapa que se han propuesto en la literatura, y que se describen de forma más detallada en el siguiente capítulo, son [8],[13],[14]:

- Algoritmos de reducción de dimensionalidad (*Feature selection*) [15]:
 - *Principal Component Analysis* (PCA): técnica que lleva a cabo una transformación ortogonal convirtiendo las observaciones de un conjunto de variables originales a un conjunto de variables linealmente independientes, denominadas componentes principales, y ordenadas de mayor a menor varianza.
 - *Independent Component Analysis* (ICA): análisis multivariado que se basa en la optimización de un criterio de independencia entre las señales observadas que permite representar los datos mediante un conjunto de componentes estadísticamente independientes con distribución no gaussiana utilizando una proyección lineal no ortogonal [16].

- *Minimum Noise Fraction* (MNF): técnica que transforma el cubo de datos con ruido en un conjunto de canales con niveles crecientes de ruido mediante una primera etapa de decorrelación y reescalado del ruido (*noise whitening*) y la aplicación posterior de PCA [17].
- Algoritmos de agrupación de píxeles de la imagen hiperespectral:
 - *K-means*: método que divide el conjunto de observaciones en k grupos, asociando cada dato al grupo con el centroide más cercano, con el objetivo de minimizar la varianza de los datos pertenecientes a cada grupo.
 - *Mean-Shift*: algoritmo basado en el uso de ventanas deslizantes que se actualizan y convergen hacia áreas con más densidad de puntos.
 - Medidas de similitud: método que consiste en comparar el espectro de cada píxel con un conjunto de espectros de referencia aplicando métricas como SAM (*Spectral Angle Mapper*) o la distancia euclídea para medir la similitud entre los espectros.

Una vez segmentada la imagen, se debe llevar a cabo la detección de posibles objetos ocultos o blancos de interés utilizando algoritmos de detección de anomalías, dado que no tenemos información a priori de las firmas espectrales de los materiales que se desean detectar. Estos algoritmos determinan si la firma espectral de cada píxel es significativamente diferente a la de los píxeles vecinos considerados como fondo de la imagen. Uno de los detectores más usados en este campo es el detector de anomalías Reed- Xiaoli (RX), que se ha aplicado con éxito en muchas aplicaciones de detección de blancos en imágenes hiperespectrales, y es considerado el algoritmo de detección de anomalías de referencia para esta tecnología. Este detector se fundamenta en el *Generalized Likelihood Ratio Test* (GLRT) determinando la distancia de Mahalanobis entre la firma espectral del píxel analizado y la firma espectral media de un conjunto de píxeles de referencia, que presentan una matriz de covarianza muestral [18, 19]. Se han propuesto múltiples modificaciones de este algoritmo como, por ejemplo, el *Subspace RX* (SSRX), que realiza una descomposición del cubo de datos en subespacios de menor dimensionalidad, aplica RX a cada subespacio y fusiona, finalmente, los resultados obtenidos.

Tras detectar las posibles anomalías presentes en la imagen, se propone aplicar una última etapa de clasificación, con el objetivo de minimizar las falsas alarmas del sistema y reportar únicamente las anomalías que corresponden a materiales de los blancos de interés o relacionados con el desarrollo de posibles actividades ilícitas. En esta etapa, se debe tener en cuenta que, debido a la limitada resolución espacial de los sensores hiperespectrales, la firma espectral en cada píxel puede ser una composición de firmas hiperespectrales de diversos materiales. Por este motivo, los principales algoritmos considerados en esta etapa son aquellos que permiten realizar una clasificación de los distintos materiales que componen píxeles posiblemente mixtos, entre los que destacan los algoritmos basados en *sparse regression*, que, asumiendo que la firma espectral de cada píxel es una combinación lineal de un pequeño conjunto de firmas espectrales tomadas de una base de datos, determinan el conjunto óptimo que mejor modela la firma espectral de cada píxel.

1.3. Objetivos

El objetivo principal de este trabajo de fin de grado es realizar la cadena de procesamiento de datos explicada en la Figura 1.2 consiguiendo desarrollar algoritmos para la detección de anomalías en imágenes. Para abordar este tema necesitaremos ir cumpliendo los siguientes objetivos secundarios

1. Realizar un estudio del arte de la tecnología hiperespectral.
2. Analizar los algoritmos de procesamiento de imágenes hiperespectrales, tanto para detectar materiales con firmas espectrales conocidas, como para detección de anomalías, en los que no se dispone de información a priori de los materiales que se desean detectar.
3. Proponer e implementar una cadena de procesado que incluya los algoritmos de reducción de dimensionalidad, segmentación, detección de anomalías y clasificación consiguiendo reconocer materiales como plásticos o metales posiblemente camuflados.
4. Evaluar las capacidades de la cadena de procesado implementada utilizando imágenes hiperespectrales sintéticas simuladas con Matlab.
5. Aplicar el procesado desarrollado a imágenes hiperespectrales y multiespectrales reales obtenidas con distintos sensores embarcados en plataformas aéreas y satelitales disponibles en bases de datos públicas.
6. Obtener conclusiones a partir de los resultados obtenidos con las imágenes reales y simuladas e identificar posibles líneas futuras de trabajo.

Capítulo 2

Estado del arte

En este capítulo, se describen los fundamentos de la tecnología hiperespectral, los modos de adquisición de las imágenes y las correcciones que se llevan a cabo para compensar el efecto de la atmósfera. Además, se detallan las características más importantes de estos sensores y las principales plataformas en las que se embarcan. Finalmente, se desarrollan los algoritmos en los que se basa la cadena de procesamiento propuesta en este trabajo para la detección y clasificación de anomalías en imágenes hiperespectrales.

2.1. Fundamentos de la tecnología hiperespectral

La idea básica que justifica la adquisición de imágenes hiperespectrales para aplicaciones de *remote sensing* es el hecho de que cada material presenta una curva característica de radiación reflejada, absorbida o emitida que varía con la longitud de onda. Los sensores hiperespectrales son dispositivos que permiten medir la energía radiada, compuesta por la radiación reflejada y la emitida por los materiales, en el área correspondiente a cada píxel de la imagen para un gran número de bandas espectrales. Estas curvas espectrales están relacionadas principalmente con los siguientes procesos de interacción materia-radiación [1, 20, 21]:

- Reflexión: proceso por el cual la radiación incidente no atraviesa la interfase entre dos medios y es reflejada en distintas direcciones en función del ángulo de incidencia, la superficie de reflexión y la longitud de onda de la radiación. El parámetro que se utiliza para medir dicha reflexión es la reflectancia, que viene dada por el cociente entre la potencia de la radiación refleja y la potencia de la radiación incidente. La variación de la reflectancia en función de la longitud de onda en el espectro visible determina los diferentes colores de los objetos.
- Emisión: proceso por el cual los materiales emiten radiación electromagnética debido a su temperatura. De acuerdo a la ley de Stefan-Boltzmann, la potencia de la radiación emitida es proporcional a la cuarta potencia de la temperatura del objeto.

Las bandas espectrales más empleadas por la tecnología hiperespectral para aplicaciones de *remote sensing* son el espectro visible (0.4 - 0.7 μm) y las zonas NIR (0.7 - 1.4 μm) y SWIR (1.4 - 3 μm), debido a que en ellas el espectro es predominantemente reflectivo, facilitando las operaciones de compensación atmosférica y la extracción de información para la clasificación

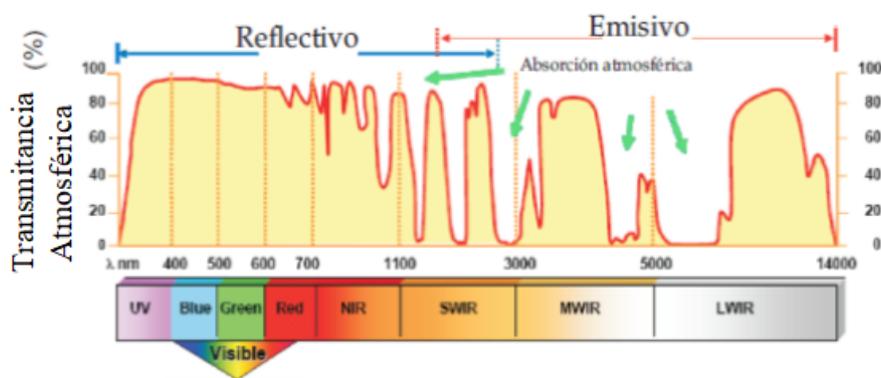


Figura 2.1: Espectro electromagnético y transmitancia atmosférica. En las bandas UV, visibles, NIR y SWIR, los espectros son predominantemente reflectivos, mientras que en las bandas MWIR y LWIR predomina la componente de emisividad [23].

de los materiales [22]. En cambio, como se representa en la Figura 2.1, en las zonas MWIR (*Medium-wavelength infrared*, 3 - 5 μm) y LWIR (*Long-wavelength infrared*, 5 - 15 μm) predomina la componente de emisividad y existen importantes bandas de absorción atmosférica.

Para la generación de la imagen hiperespectral, es importante tener en cuenta la respuesta de la atmósfera y el espectro de la radiación solar, con el objetivo de compensar su efecto y determinar el espectro de reflectancia de los materiales presentes en cada píxel. Como se representa en la Figura 2.2, los procesos de compensación atmosférica permiten obtener la firma de reflectancia de los objetos a partir de la curva de radiancia medida por el sensor al considerar las curvas de radiación solar y transmitancia atmosférica. Sin embargo, existen bandas en las que la absorción atmosférica es muy elevada, debido principalmente a la presencia de moléculas de oxígeno y vapor de agua, y que no son consideradas en el posterior análisis de la imagen hiperespectral debido a su reducida relación señal a ruido (SNR).

Actualmente, se emplean principalmente dos tecnologías para el desarrollo de los sensores hiperespectrales, que convierten de forma cuantitativa los fotones incidentes en una intensidad de corriente: la tecnología CDD (*Charge Coupled Device*) y la tecnología CMOS (*Complementary Metal Oxide Semiconductor*) [14, 25]. Los fotodiodos utilizados se fabrican en diferentes materiales en función de las bandas medidas del espectro. Por ejemplo, el silicio se utiliza para la adquisición de las bandas ultravioleta, visibles y NIR, mientras que el arseniuro de indio (InAs) o el arseniuro de galio (GaAs) se emplean para medir en el rango de 900 a 1700 nm.

Estos sensores permiten generar la imagen hiperespectral utilizando distintos modos de adquisición en función de cómo realizan la exploración espacial y espectral (Figura 2.3) [5, 25, 26]:

- Modo Whiskbroom (exploración por puntos): el detector mide simultáneamente todas las bandas espectrales en cada píxel y explora el espacio x-y para generar el cubo de datos. La exploración en dos dimensiones limita en gran medida la velocidad de adquisición.
- Modo Pushbroom (exploración por líneas): el sensor adquiere simultáneamente todas las bandas consideradas de una línea completa de píxeles, realizando la exploración espacial

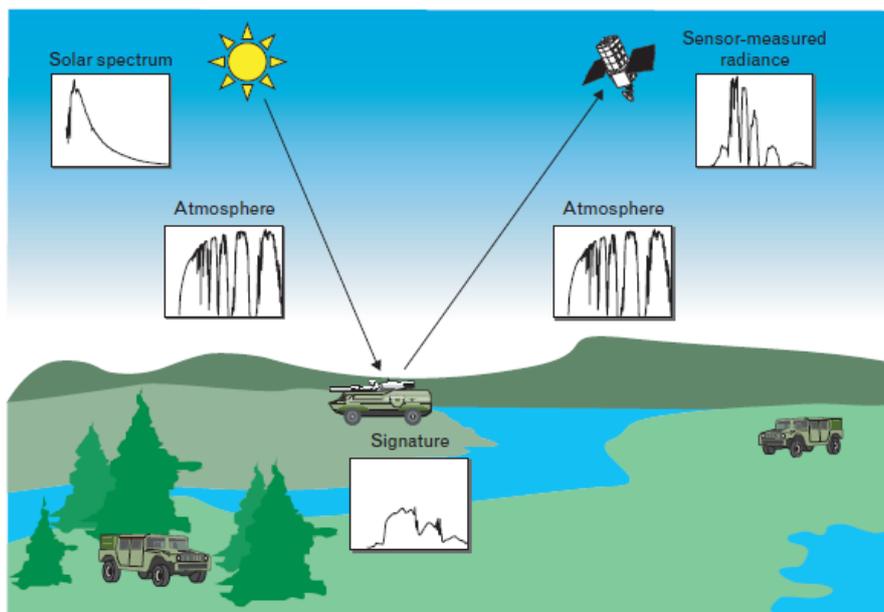


Figura 2.2: Proceso de adquisición de imágenes hiperespectrales [24]. La reflectancia de los materiales puede ser obtenida a partir de la radiancia medida tras un proceso de compensación atmosférica que tenga en cuenta el espectro de la radiación solar y la curva de transmitancia de la atmósfera.

en una sola dimensión. Este modo de adquisición permite obtener una mayor SNR o una mayor velocidad de adquisición.

- Exploración por planos: el sensor mide en cada adquisición una banda espectral para todo el espacio x-y considerado y varía la longitud de onda medida entre adquisiciones para formar el cubo de datos intercalando estas bandas. Este modo no es adecuado para sensores embarcados en plataformas móviles o para escenario en movimiento.
- Modo de disparo único: el sensor adquiere de forma simultánea todo el cubo de datos hiperespectral. Este modo de adquisición, que permitiría aumentar de forma considerable la velocidad de adquisición de las imágenes hiperespectrales, se encuentra actualmente en fase de desarrollo, ya que limita de forma considerable la resolución espacial obtenida.

Las características del sensor hiperespectral y el modo de adquisición utilizado determinan las siguientes especificaciones técnicas de las cámaras hiperespectrales, que van a establecer sus capacidades operativas para la detección y clasificación de blancos:

- Resolución espacial: corresponde al área terrestre correspondiente a cada píxel y está relacionada con el objeto más pequeño que se puede distinguir. La resolución espacial depende del campo de visión correspondiente a cada píxel (*Instantaneous Field-of-View*, IFOV), al ángulo de tilt de la cámara que en este caso suele ser perpendicular a la superficie terrestre y a la altura de vuelo de la plataforma (Figura 2.4), y suele ser del orden de las decenas de metros para las cámaras hiperespectrales embarcadas. Esta limitada resolución espacial da lugar, generalmente, a píxeles no puros (*mixed pixels*) con múltiples materiales que presentan una curva espectral que es composición de las firmas espectrales de los materiales presentes, dificultando la detección de objetos y la clasificación de los materiales [10].

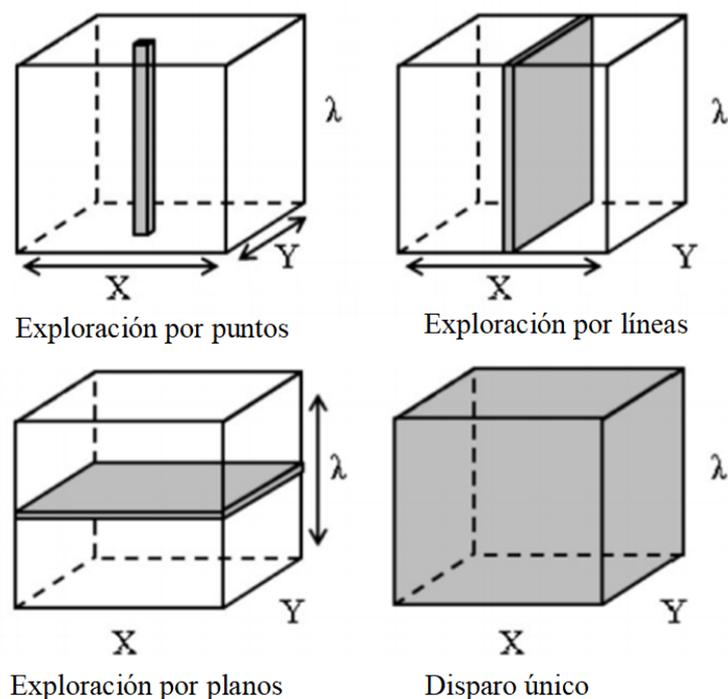


Figura 2.3: Modos de adquisición de los sensores hiperespectrales [5].

- Resolución espectral y número de bandas: corresponden con la anchura FWHM (*Full Width at Half Maximum*) de cada banda y el número de bandas espectrales adquiridas por el sensor. Incrementar el número de bandas y mejorar la resolución espectral permite aumentar las capacidades de discriminación y clasificación de los objetos y materiales. Los anchos de banda más comunes en las cámaras hiperespectrales actuales varían entre 5 y 15 nm, y se han desarrollado sensores de hasta 1000 bandas espectrales. Esta mejora respecto a las cámaras multispectrales, con anchos de banda entre 50 y 120 nm y hasta 20 bandas, permite obtener curvas más detalladas del comportamiento espectral en cada píxel (Figura 2.5) [10].
- Sensibilidad radiométrica: está determinada por el número de bits utilizados para representar la radiación medida por el sensor en cada banda en base al convertor analógico-digital empleado [1].
- Tiempo de revisita: indica el intervalo de tiempo entre dos adquisiciones consecutivas de una misma área de interés. En las plataformas aéreas, depende de la trayectoria de vuelo planificada y de la velocidad de adquisición de las imágenes. En cambio, para las plataformas satelitales, el tiempo de revisita depende de la órbita del satélite y es el periodo entre dos pases consecutivos sobre la misma zona terrestre, aunque existen constelaciones de satélites que permiten disminuir el tiempo de revisita efectivo.

En el diseño y desarrollo de los sensores hiperespectrales, se debe alcanzar un compromiso entre la resolución espacial, la resolución espectral y el tiempo de adquisición dependiendo de la aplicación específica para la que se emplean los datos hiperespectrales. Aunque el empleo de sensores hiperespectrales en el ámbito de la agricultura de precisión y en aplicaciones geocientíficas está muy extendido, han surgido en los últimos años nuevas aplicaciones emergentes,

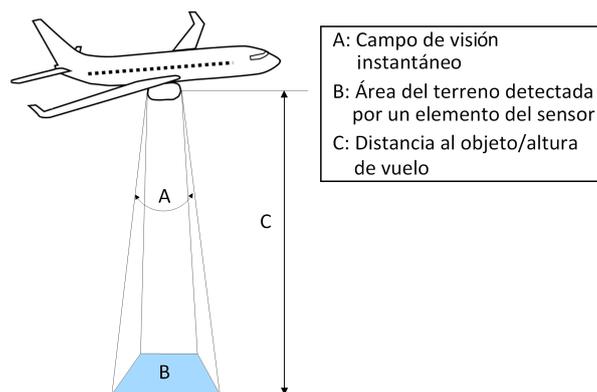


Figura 2.4: Factores que determinan la resolución espacial de un sensor hiperespectral [27].

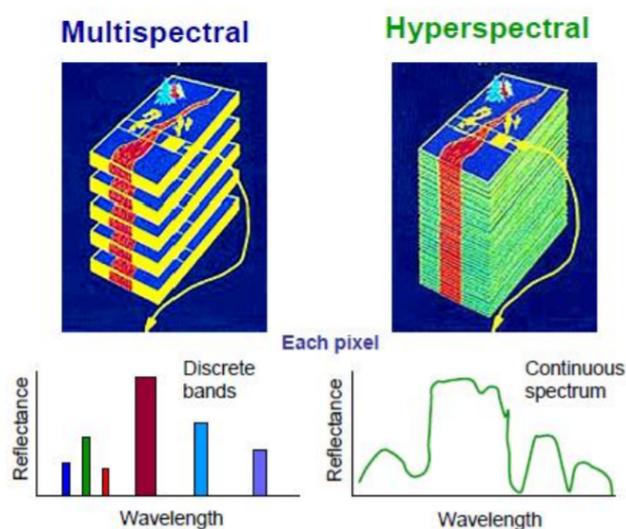


Figura 2.5: Comparación de la resolución espectral en sensores hiperespectrales y multiespectrales [28].

detalladas en el Anexo C, en los ámbitos de la medicina, de los análisis forenses o de la defensa y la seguridad, debido al desarrollo de la tecnología hiperespectral y de los algoritmos de procesamiento de las imágenes hiperespectrales. Sin embargo, la elevada carga computacional asociada a la generación y procesamiento de la imagen hiperespectral, sigue siendo un factor limitante en determinadas aplicaciones, especialmente en las que requieren la operación en tiempo real.

Además, se han desarrollado gran variedad sensores hiperespectrales embarcados en plataformas aéreas y satelitales, algunos de los cuales se describen en el Anexo D. Entre ellos, destacan el sensor Hyperion del satélite EO-1 (operativo hasta el año 2017), los sensores AVIRIS y HYDICE embarcados en plataformas aéreas y el sensor multiespectral del Sentinel-2, que proporcionan acceso público a sus datos.

2.2. Procesamiento de datos hiperespectrales

En base a la cadena de procesado propuesta e implementada en MATLAB, representada en la Figura 1.2 en este apartado nos centraremos en las etapas representadas en la Figura 2.6, para la detección y clasificación de blancos ocultos en imágenes hiperespectrales, a continuación, se detallan los algoritmos utilizados en cada una de sus etapas: (1) Reducción de dimensionalidad (*Feature Extraction*); (2) Segmentación de la imagen; (3) Detección de anomalías, y (4) Clasificación del material.

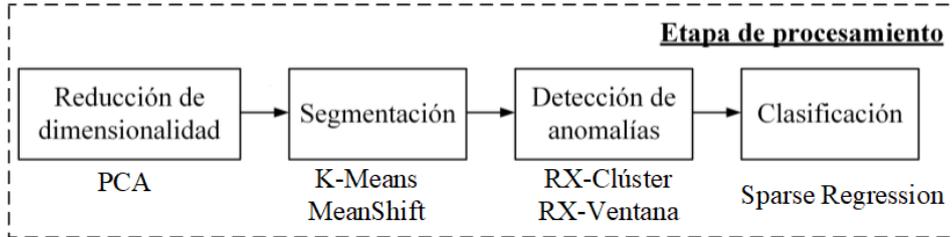


Figura 2.6: Diagrama de las etapas de procesamiento que se seguirán en este trabajo.

2.2.1. Reducción de dimensionalidad basada en PCA

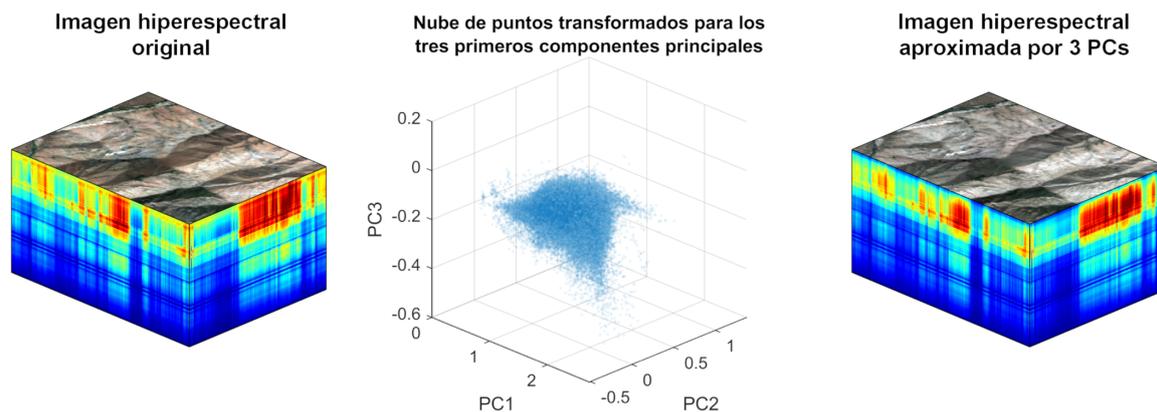
Los algoritmos de reducción de dimensionalidad o de extracción de parámetros permiten disminuir la dimensionalidad del problema original, en el que existen variables correlacionadas, representando los datos en base a un número inferior de nuevas variables [23].

Existen principalmente dos métodos para el cálculo de las componentes principales: (1) Descomposición en valores propios (*Eigenvalue decomposition*, EIG) de la matriz de covarianzas, y (2) Descomposición en valores singulares (*Singular Value Decomposition*, SVD) de la matriz centrada A de datos (obtenida restando a cada variable su media) de tamaño $N \times P$, donde N es el número de observaciones y P el número de variables. La descomposición SVD de la matriz A viene dada por:

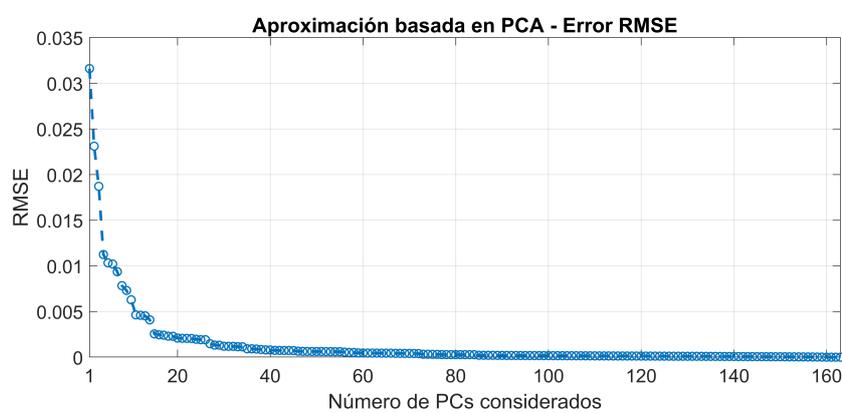
$$A = U_{m \times m} * \Sigma_{m \times n} * V_{n \times n}^T \quad (2.1)$$

donde U es una matriz ortonormal con los autovectores de $A \cdot A^T$, V es una matriz ortonormal con los autovectores de $A^T \cdot A$ (proporcional a la matriz de covarianza de las variables originales), que corresponden con los componentes principales, y Σ es una matriz diagonal que contiene las raíces cuadradas de los autovalores de $A \cdot A^T$ y $A^T \cdot A$.

De esta forma, se pueden aproximar los datos originales mediante una proyección sobre el subespacio de dimensión reducida generado por los primeros componentes principales (PC). La Figura 2.7 representa los resultados de aplicar el algoritmo PCA a una imagen hiperespectral tomada por el sensor AVIRIS [29]. Como puede observarse, aumentar el número de PCs considerados permite reducir el error de la aproximación a costa de aumentar la dimensionalidad de los datos transformados. Por este motivo, en la cadena de procesado implementada, se han considerado los tres primeros componentes principales para realizar la segmentación de la imagen, con el objetivo de limitar la carga computacional necesaria pero permitiendo la discriminación de los distintos materiales.



(a) Imagen original, nube de puntos transformados para los tres primeros PCs e imagen aproximada por los tres primeros PCs.



(b) RMSE en función del número de PCs considerados en la aproximación

Figura 2.7: Ejemplo de aplicación de PCA sobre una imagen hiperespectral capturada por el sensor AVIRIS.

2.2.2. Segmentación de imágenes hiperespectrales

La segmentación de imágenes permite dividir una imagen en zonas con características similares. En la cadena de procesamiento propuesta, el objetivo principal de la segmentación es agrupar los píxeles que presentan características espectrales similares para, posteriormente, determinar la matriz de covarianza muestral de dicha zona y emplearla en el detector de anomalías. De esta forma, se reduce la carga computacional necesaria respecto a otras técnicas de cálculo de la matriz de covarianza como el método de ventana deslizante, que se describirá posteriormente.

Los dos tipos de segmentación más utilizados son: (1) Segmentación basada en bordes, que delimita las regiones detectando sus fronteras a través de métodos como la transformada de Hough o algoritmos de detección de bordes como Canny o Sobel, y (2) segmentación basada en regiones, que divide la imagen en regiones con características similares. Este segundo tipo de segmentación, que permite la agrupación de zonas del mismo material espacialmente separadas, es más utilizado en imágenes hiperespectrales, y es el que emplearemos en la cadena de procesamiento implementada considerando como parámetros de discriminación las proyecciones sobre los tres

primeros componentes principales. Para ello, se ha evaluado el funcionamiento sobre imágenes hiperespectrales de los algoritmos de segmentación *K-means* y *Mean-Shift* [30, 31].

K-means

Este algoritmo permite agrupar los n puntos $(\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)$ en k conjuntos $(\mathbf{S} = \{S_1, S_2, \dots, S_k\})$, de tal forma que se minimice la suma de las distancias al cuadrado entre cada punto y el centroide $\boldsymbol{\mu}_i$ del clúster más cercano, es decir, la varianza respecto al centroide de cada clúster:

$$\arg \min_{\mathbf{S}} \sum_{i=1}^k \sum_{\mathbf{x} \in S_i} \|\mathbf{x} - \boldsymbol{\mu}_i\|^2 \quad (2.2)$$

Para implementar este algoritmo de forma iterativa se siguen los siguientes pasos:

1. Inicialización del algoritmo seleccionando k datos, que constituyen los centroides iniciales de cada clúster. Esta inicialización se ha realizado seleccionando k datos aleatorios.
2. Asignación de los puntos al clúster i cuyo centroide se encuentre a la mínima distancia euclídea:

$$\arg \min_i \|\mathbf{x} - \boldsymbol{\mu}_i\| \quad (2.3)$$

3. Actualización de los centroides de cada clúster con la media de los datos asignados:

$$\boldsymbol{\mu}_i = \frac{1}{|S_i|} \sum_{\mathbf{x} \in S_i} \mathbf{x} \quad (2.4)$$

4. Repetir los pasos 2 y 3 hasta que no se produzcan cambios en los datos asignados a cada clúster.

La Figura 2.8 muestra el resultado de aplicar el algoritmo *K-means* implementado a la nube de puntos transformados sobre los tres primeros componentes principales de la imagen hiperespectral representada en la Figura 2.7.a, utilizando dos posibles valores del parámetro k . La principal desventaja de este algoritmo para su aplicación en imágenes arbitrarias de escenarios reales es la elección del parámetro k , cuyo valor adecuado depende del número de zonas de la imagen a priori desconocidas. Por este motivo, se ha implementado también el algoritmo *Mean-shift*, que no requiere especificar como parámetro el número de clústers.

Mean-shift

Dado un conjunto de datos, en cada iteración, este algoritmo asigna a cada clúster los datos que se encuentren en el interior de una cierta ventana alrededor de su centroide y actualiza cada centroide con la media de los datos asignados. De esta forma, los centroides iniciales se desplazan hacia zonas con mayor densidad de puntos hasta obtener una segmentación de la imagen en la que cada punto se asigna al clúster con el centroide más cercano obtenido con este algoritmo.

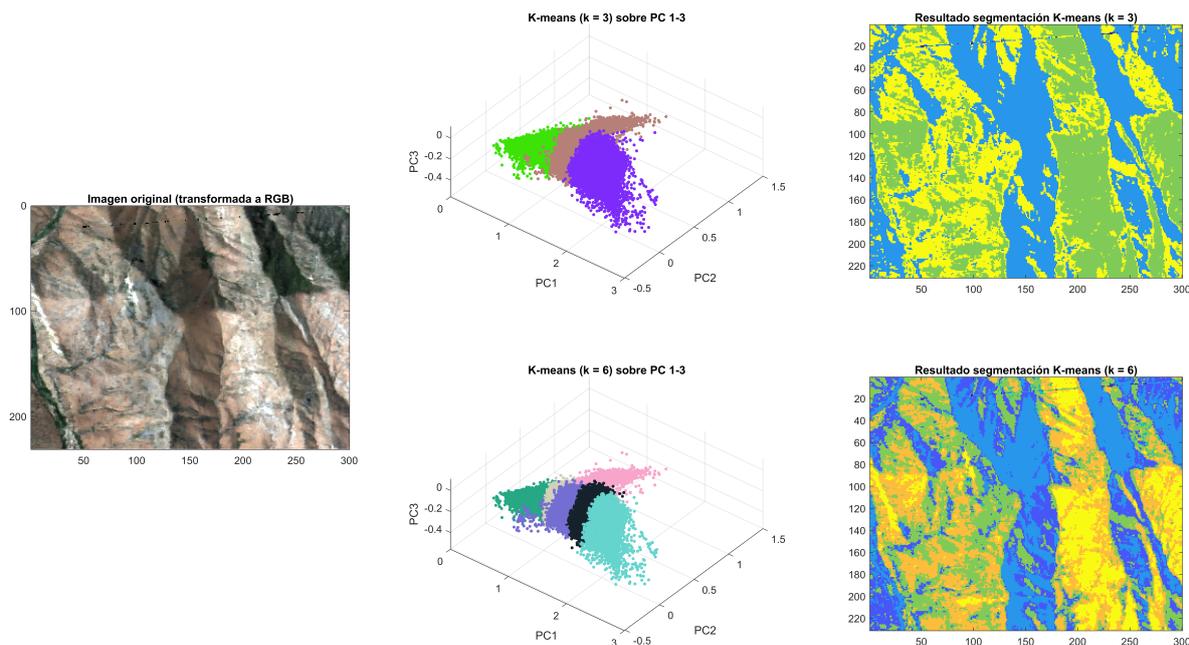


Figura 2.8: Algoritmo *K-means* aplicado sobre una imagen hiperespectral para $k = 3$ y $k = 6$ (cada color corresponde a un clúster).

En el algoritmo implementado, se han considerado ventanas esféricas definidas por su radio, que debe especificarse como parámetro y que influye en el número de clústers que genera este algoritmo. Los centroides iniciales se distribuyen de forma uniforme en el espacio tridimensional considerado entre los límites máximo y mínimo de los datos en las tres dimensiones. Además, en cada iteración, se filtran los clústers que no presentan puntos asignados y se fusionan aquellos clústers cuyos centroides están próximos.

La Figura 2.9 representa la inicialización de los centroides y su actualización en la primera iteración al aplicar el algoritmo implementado a la nube de puntos de la imagen hiperespectral transformada sobre los tres primeros componentes principales. Como puede observarse, los centroides se desplazan hacia zonas de mayor densidad de puntos. A su vez, la Figura 2.10 muestra los resultados obtenidos al aplicar el algoritmo *Mean-shift* sobre la imagen hiperespectral de la Figura 2.7.a, segmentando la imagen en ocho zonas.

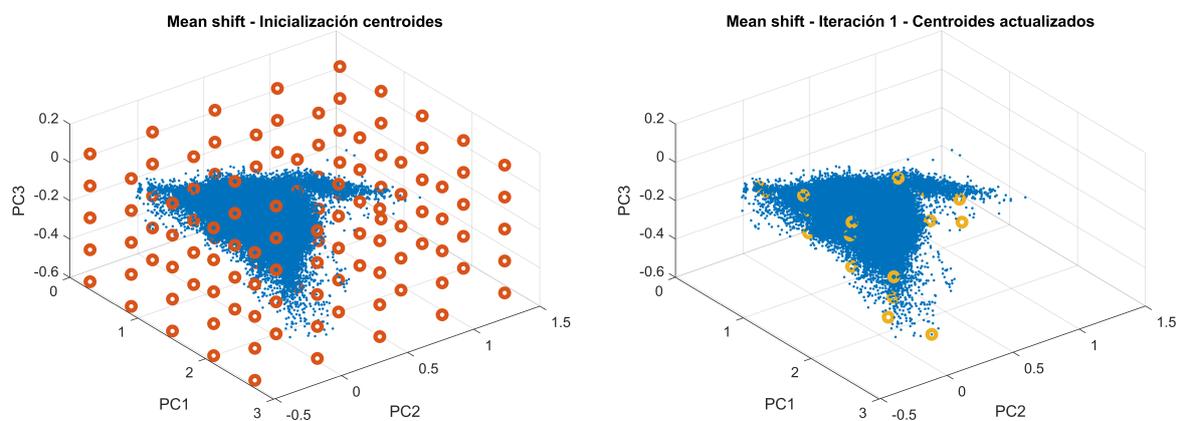


Figura 2.9: Ejemplo de inicialización de los centroides (puntos rojos) en el algoritmo *Mean-shift* (izq.) y de su actualización (puntos amarillos) en la primera iteración hacia zonas con mayor densidad de puntos (dcha.).

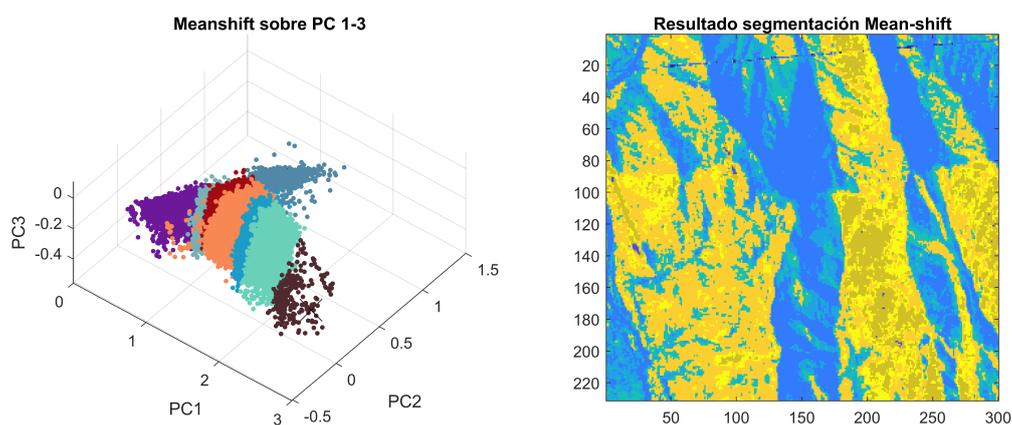


Figura 2.10: Algoritmo *Mean-shift* aplicado sobre una imagen hiperespectral (cada color corresponde a un clúster).

2.2.3. Algoritmos para la detección de anomalías

Cuando se emplean imágenes hiperespectrales para la detección de blancos u objetos ocultos, generalmente, no se dispone de suficiente información a priori para especificar 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 espectral significativa respecto de los píxeles considerados como fondo.

El algoritmo Reed-Xiaoli (RX) [32, 33] es un detector de anomalías adaptativo con características CFAR (*Constant False Alarm Rate*) que se basa en el GLRT (*Generalized-Likelihood Ratio Test*).

En el enfoque GLRT, se considera que la función de densidad de probabilidad (pdf) de los datos presenta una forma paramétrica dada por los parámetros θ que se estiman con los datos de referencia y de test. El conjunto de datos de referencia (píxeles del fondo) $\{v_j \in C^K | 1 \leq j \leq N\}$ se asume que presenta N muestras independientes e idénticamente distribuidas (iid) de dimensión K con una fdp dada por $p_0(\cdot, \theta_0)$, mientras que el conjunto de datos de test $\{x_\ell \in C^K | 1 \leq \ell \leq M\}$ debe clasificarse en función de si presenta una fdp dada por $p_1(\cdot, \theta_1)$ (Hipótesis alternativa, H_1) o por $p_0(\cdot, \theta_0)$ (Hipotesis nula, H_0). Para ello, el GLRT viene dado por la expresión (2.5) [33] en la que se compara con un umbral η que establece la probabilidad de falsa alarma.

$$G(x) = \frac{\max_{\theta_1} (p_1(\{x_\ell\}, \theta_1) p_0(\{v_j\}, \theta_1))}{\max_{\theta_0} (p_0(\{x_\ell\}, \theta_0) p_0(\{v_j\}, \theta_0))} \underset{H_0}{\overset{H_1}{\gtrless}} \eta \quad (2.5)$$

El algoritmo RX, aplicable a imágenes hiperespectrales, asume que el espectro de los píxeles con blancos (s) y el espectro (μ) y la matriz de covarianza (Γ_x) del fondo son desconocidos. Modelando los datos mediante distribuciones normales $N(\mu, \Gamma)$ de media μ y covarianza Γ , las hipótesis H_0 y H_1 vienen dadas por:

$$\begin{aligned} H_0 : x &\rightarrow N(\mu, \Gamma_x) \\ H_1 : x &\rightarrow N(s, \Gamma_x) \end{aligned} \quad (2.6)$$

De esta forma, siendo x el espectro del píxel bajo test y $\{v_j \in C^K | 1 \leq j \leq N\}$ el conjunto de datos de referencia, el GLRT para el algoritmo RX, asumiendo blancos de un solo píxel, es:

$$RX(x) = (x - \hat{\mu})^T \left(\frac{N}{N+1} \hat{\Gamma}_x + \frac{1}{N+1} (x - \hat{\mu})(x - \hat{\mu})^T \right)^{-1} (x - \hat{\mu}) \underset{H_0}{\overset{H_1}{\gtrless}} \eta \quad (2.7)$$

donde $\hat{\mu} = \frac{1}{N} \sum_{j=1}^N v_j$ es la media muestral y $\hat{\Gamma}_x = \frac{1}{N} \sum_{j=1}^N (v_j - \hat{\mu})(v_j - \hat{\mu})^T$ es la matriz de covarianza muestral de los datos de referencia. Por tanto, la expresión (2.7) determina la distancia de Mahalanobis entre la observación x bajo test y la firma espectral media $\hat{\mu}$ del fondo y compara el resultado con un umbral, que fija la probabilidad de falsa alarma, para determinar

si el píxel bajo test es o no una anomalía.

El conjunto de referencia, que debe contener más píxeles que el número de bandas espectrales consideradas, suele seleccionarse a partir de una ventana de referencia cuadrada alrededor de la celda bajo test, dejando unas celdas de guarda para evitar el auto-ocultamiento del blanco en escenarios con blancos extensos que ocupan más de un píxel, como se representa en la Figura 2.11. Sin embargo, este procedimiento implica calcular una media y una matriz de covarianza muestrales para cada celda bajo test, aumentando considerablemente la carga computacional del algoritmo.

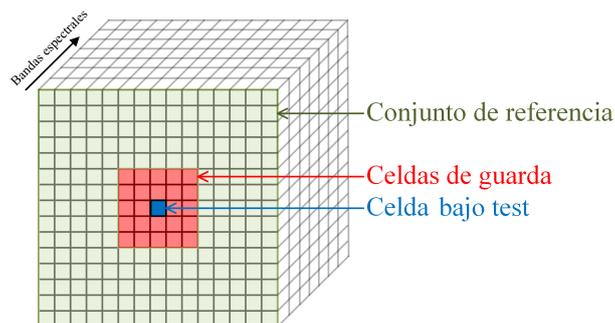


Figura 2.11: Ventana de referencia para estimar la media y matriz de covarianza muestrales en una zona localizada alrededor de la celda bajo test.

Por este motivo, con el objetivo de reducir la carga computacional necesaria, en la cadena de procesado implementada, se calculan la media y matriz de covarianza muestrales de cada clúster obtenido del algoritmo de segmentación, y se compara el espectro medido en cada píxel aplicando el algoritmo RX con la media y matriz de covarianza muestrales del clúster al que pertenece.

Como el algoritmo de detección de anomalías no determina el tipo de material detectado, se propone aplicar posteriormente un algoritmo de clasificación sobre las anomalías obtenidas con el objetivo de determinar qué anomalías corresponden con objetos camuflados y objetos de interés y cuáles pueden considerarse falsas alarmas debidas a elementos naturales de la escena.

2.2.4. Algoritmos para la clasificación de anomalías

Normalmente los espectros medidos por los sensores hiperespectrales son mezclas de los espectros de varios materiales debido principalmente a la baja resolución espacial que da lugar a píxeles no puros. Por esta razón, para clasificar los materiales presentes en un píxel, es necesario realizar un desmezclado (*unmixing*) para obtener los componentes (*endmembers*) con sus firmas espectrales características y sus abundancias. El problema del *unmixing* presenta dificultades debidas a las inexactitudes de los modelos utilizados, al ruido de observación, a los efectos de las condiciones ambientales y a la variabilidad de las firmas espectrales de los materiales.

Existen diferentes técnicas para modelar la mezcla de las firmas espectrales 2.12, entre las que destaca el modelo de mezcla lineal [20], que asume que la curva espectral medida para un

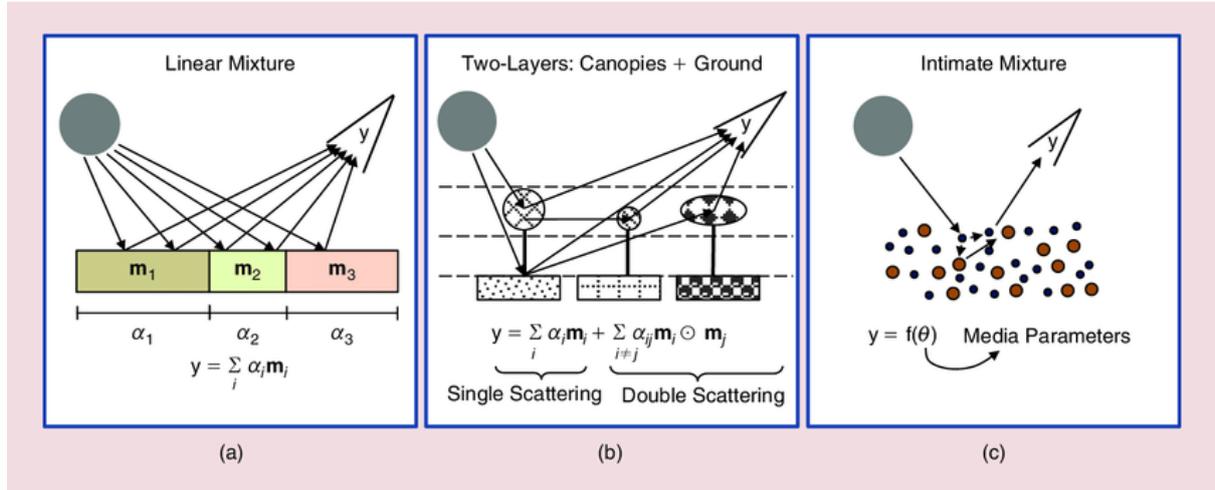


Figura 2.12: Modelos de mezcla. a) Mezclado lineal donde el espectro medido es una media ponderada de los espectros de los materiales b) Mezcla no lineal íntima donde los materiales están muy cerca c) Mezcla no lineal con múltiples interacciones entre capas [20].

píxel es una combinación lineal de las firmas espectrales de los componentes. De esta forma, considerando p componentes, el espectro medido $\mathbf{x} \equiv [x_1, x_2, \dots, x_B]$ en B bandas espectrales viene dado por:

$$\mathbf{x} = \mathbf{M}\alpha + \mathbf{w} \quad (2.8)$$

donde $\alpha \equiv [\alpha_1, \alpha_2, \dots, \alpha_p]^T$ es el vector de abundancias, cuyos elementos son no negativos, suman uno y representan la abundancia de cada material, $\mathbf{M} \equiv [\mathbf{m}_1, \mathbf{m}_2, \dots, \mathbf{m}_p]$ es una matriz cuyas columnas son las firmas espectrales para las B bandas de los materiales considerados ($\mathbf{m}_j \equiv [\rho_{1j}, \rho_{2j}, \dots, \rho_{Bj}]^T$), y $\mathbf{w} \equiv [w_1, w_2, \dots, w_B]^T$ es el vector de perturbaciones que incluye el ruido y los errores del modelo.

A partir de este modelo de mezcla lineal, se puede llevar a cabo un algoritmo de *unmixing* basado en técnicas *sparse regression* [34] para encontrar el subconjunto óptimo de firmas espectrales de una base de datos $\mathbf{A} \in \mathbb{R}^{B \times m}$, con las firmas espectrales de m materiales medidas en B bandas (generalmente $m > B$), que mejor modela la curva espectral \mathbf{x} de cada píxel, asumiendo que, generalmente, el número de materiales presentes en cada píxel es reducido. El problema de *sparse regression* para obtener el vector de abundancias α puede expresarse como un problema de minimización:

$$\min_{\alpha} \|\alpha\|_0 \quad \text{sujeto a} \quad \|\mathbf{A}\alpha - \mathbf{x}\|_2 \leq \delta, \alpha \succeq 0 \quad (2.9)$$

donde $\|\alpha\|_0$ representa el número de componentes no nulas del vector de abundancias α y $\delta \geq 0$ es la tolerancia al error debido a ruido o al modelado. Para resolver este problema de optimización, se han propuesto aproximaciones convexas que sustituyen $\|\cdot\|_0$, frecuentemente llamada norma ℓ_0 , por la norma ℓ_1 , como la aproximación CBPDN (*Constrained basispursuitdenoising*) [34]:

$$\min_{\alpha} \|\alpha\|_1 \quad \text{sujeto a} \quad \|\mathbf{A}\alpha - \mathbf{x}\|_2 \leq \delta, \alpha \succeq 0 \quad (2.10)$$

que presenta una formulación equivalente, denominada CSR (*Constrained sparse regression*), dada por:

$$\min_{\alpha} \left(\frac{1}{2} \right) \| \mathbf{A}\alpha - \mathbf{x} \|_2 + \lambda \| \alpha \|_1 \quad \text{sujeto a } \alpha \succeq 0 \quad (2.11)$$

donde $\lambda > 0$ está relacionada con el multiplicador de Lagrange de la desigualdad $\| \mathbf{A}\alpha - \mathbf{x} \|_2 \leq \delta$ y puede interpretarse como un parámetro de regularización. Este problema de optimización se ha resuelto en la cadena de procesado desarrollada utilizando toolbox de MATLAB [35].

De esta forma, utilizando el algoritmo de clasificación se determinan los materiales que componen cada anomalía y se declara la detección de un blanco de interés o de un objeto oculto si entre los materiales clasificados se encuentra alguno de los materiales de interés (plásticos utilizados en lonas de camuflaje, aceros, materiales metálicos, etc.) con una abundancia superior a un cierto umbral que puede seleccionarse como parámetro del procesado.

Capítulo 3

Procesamiento de imágenes sintéticas

En este capítulo, se va a evaluar el funcionamiento de la cadena de procesado implementada en MATLAB aplicada sobre cubos hiperespectrales generados sintéticamente a partir de firmas espectrales obtenidas de la base de datos de USGS [11]. A partir de una imagen hiperespectral ideal que incluye zonas con distintos materiales cuyos píxeles presentan espectros sin mezcla y sin variaciones respecto de las firmas espectrales de la base de datos, se han simulado distintos efectos que degradan la calidad de la imagen con el objetivo de evaluar el funcionamiento y la robustez de los algoritmos implementados frente a estos efectos que se producen en las imágenes reales: (1) variaciones de las firmas espectrales medidas respecto de las contenidas en la base de datos; (2) mezcla de firmas espectrales en los bordes de los materiales para considerar la presencia de varios materiales en cada píxel, y (3) ruido del sensor, que se asume ruido Gaussiano blanco espacial y espectralmente.

3.1. Generación cubos hiperespectrales sintéticos

3.1.1. Generación de las firmas hiperespectrales

Para generar las imágenes sintéticas, se han cogido las firmas espectrales de cinco materiales representativos (hierba, pino, arena, asfalto y plástico) de la base de datos USGS, que se representan en la Figura 3.1.a. La firma espectral del material plástico en el rango visible se ha modificado para simular un objeto camuflado ópticamente con la misma respuesta espectral que la hierba en el rango de $0,5 \mu\text{m}$ hasta $0,7 \mu\text{m}$. Sin embargo, en el rango de longitudes de onda a partir de $0,7 \mu\text{m}$, correspondiente con la zona de infrarrojos, las firmas espectrales de ambos materiales son completamente diferentes. Por tanto, los objetos camuflados, que se simulan con la firma espectral modificada del plástico, no podrían ser detectados en imágenes RGB, y debe utilizarse la información espectral en la zona de infrarrojos proporcionada por los sensores hiperespectrales para poder llevar a cabo su detección.

A su vez, como en las imágenes reales los píxeles correspondientes a un material suelen presentar espectros que no coinciden exactamente con la firma espectral contenida en la base de datos, se han generado firmas espectrales con variaciones respecto a la firma espectral base. Para ello, se generan vectores de ruido correlado mediante filtrado paso-bajo de secuencias de ruido blanco Gaussiano que se suman a la firma espectral base. Además, se comprueba que la diferencia máxima entre la firma generada y la firma base y que el RMSE (*root mean square*

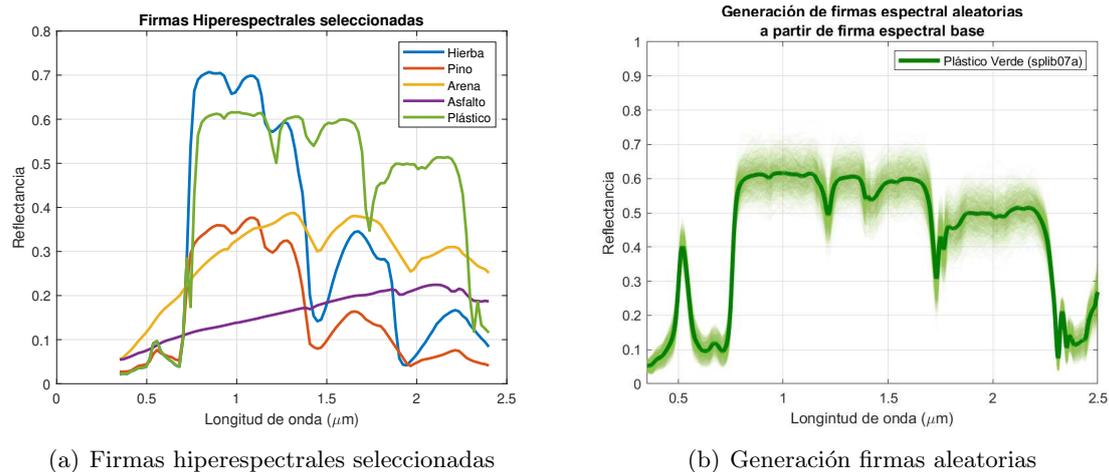


Figura 3.1: Firmas hiperespectrales seleccionadas de la base de datos y las variaciones aleatorias realizadas para formas nuestras imágenes sintéticas.

error) entre ambas firmas sean menores que ciertos umbrales establecidos como parámetros y que permiten simular distintos niveles de variación respecto a la firma base. En la Figura 3.1.b, se representa el resultado de generar múltiples firmas espectrales variadas a partir de la firma espectral del plástico verde contenida en la base de datos, donde la parte difuminada alrededor de la firma original son las diferentes firmas aleatorias generadas que cumplen las condiciones de máximas diferencias impuestas por los umbrales.

3.1.2. Generación de los cubos hiperespectrales

Generación de la matriz de posición de los materiales

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 a partir de las firmas espectrales de los cinco materiales considerados. Para ello, se han construido las matrices de abundancias de los materiales de tamaño 100x100 (Figura 3.2.a), de tal forma que la imagen presenta zonas con los distintos materiales (hierba, pino, arena y asfalto) que representan el fondo. Sobre dicho fondo, se introduce un pixel de anomalía (firma espectral modificada del plástico) en cada una de las cuatro zonas consideradas.

A su vez, se ha generado otra matriz de abundancias (Figura 3.2.b) aplicando un filtro 2D gaussiano (con desviación estándar $\sigma = 0,5$) a la matriz de abundancias ideal, obteniendo un mezclado de los materiales en los bordes de las zonas. De esta forma, se pretende simular el efecto de mezcla de firmas espectrales que se produce en las imágenes reales.

Utilizando las matrices de abundancias generadas y el modelo de mezcla ideal (2.8), se han sintetizado los siguientes cubos de datos hiperespectrales, que se representan en la Figura 3.3:

1. **Cubo hiperespectral ideal** (Imagen ideal) generado con la matriz de abundancias ideal y las firmas espectrales de la base de datos (sin variación).

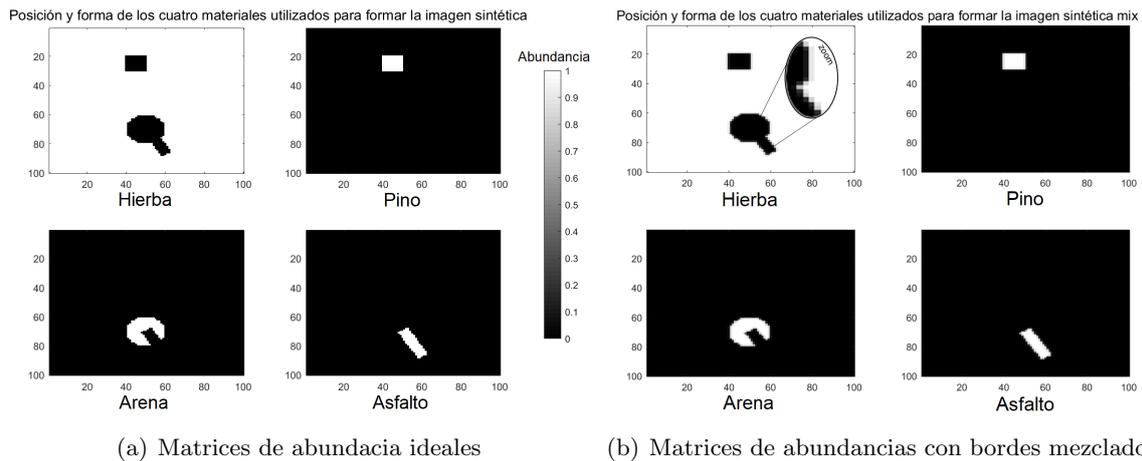
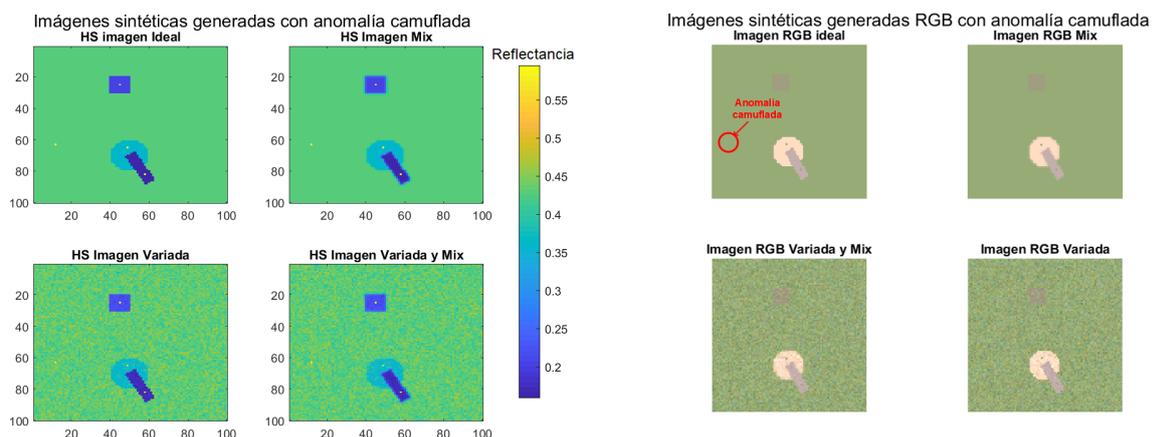


Figura 3.2: Matrices de abundancias generadas para los materiales hierba, pino, arena y asfalto.

2. **Cubo hiperspectral con mezcla** (Imagen Mix) generado con la matriz de abundancias filtrada espacialmente y las firmas espectrales de la base de datos (sin variación), para simular el efecto del mezclado de las firmas espectrales de los materiales en los bordes de las zonas.
3. **Cubo hiperspectral con firmas variadas** (Imagen variada) generado con la matriz de abundancias ideal y las firmas obtenidas con el generador implementado de firmas con variaciones respecto a las firmas espectrales base de los materiales considerados.
4. **Cubo hiperspectral con mezcla y firmas variadas** (Imagen variada y Mix) generado con la matriz de abundancias filtrada y las firmas con variaciones para incluir los dos efectos anteriores (mezcla en los bordes de las zonas y firmas espectrales con variaciones).



(a) Reflectancias en la banda 50 ($1.36 \mu\text{m}$), cortes de los cubos hiperspectrales generados, en los que puede observarse la presencia de las anomalías

(b) Transformación a RGB (espectro visible) de los cubos hiperspectrales generados, en los que la anomalía presente en la hierba se encuentra camuflada

Figura 3.3: Cubos hiperspectrales generados a partir de las matrices de abundancias y las firmas espectrales de los materiales considerados para evaluar el funcionamiento de los algoritmos implementados para la detección y clasificación de objetos camuflados.

Finalmente, para incluir el efecto del ruido del sensor, se ha añadido ruido blanco gaussiano (incorrelado espacial y espectralmente) para distintos niveles de SNR (*Signal-to-Noise Ratio*) a los cubos hiperespectrales anteriormente generados. Para ello, se ha considerado que la potencia del cubo original viene dada por la media de todos sus elementos al cuadrado. Como puede observarse en la Figura 3.4, en la que se representan los resultados obtenidos partiendo de la imagen ideal, se han generado cubos hiperespectrales para ocho niveles distintos de SNR. Aunque se han evaluado los algoritmos implementados para los distintos niveles de SNR, se representarán los resultados para unas SNR de 25 y 30 dB, que corresponden con los niveles típicos de trabajo de los sensores hiperespectrales. Además, se presentarán los resultados obtenidos para una SNR baja (5 dB) con el objetivo de analizar cómo se comportan los algoritmos implementados frente al ruido.

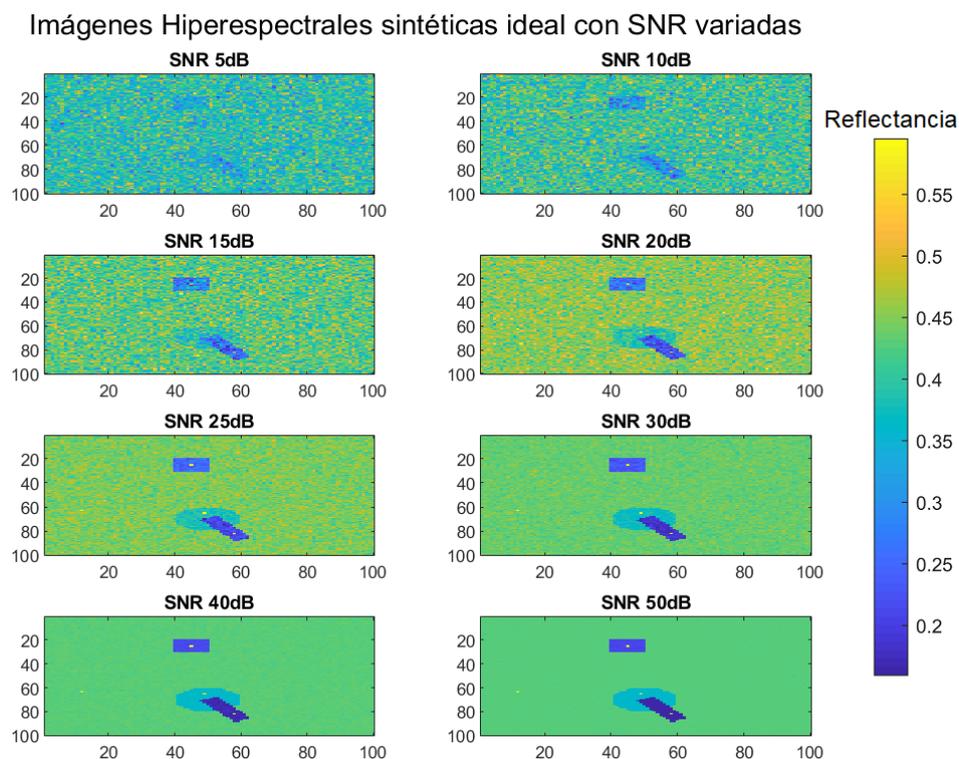


Figura 3.4: Reflectancia en la banda 50 ($1.36 \mu\text{m}$) de la imagen ideal degradada por ruido con los ocho niveles de SNR evaluados.

3.2. Segmentación de imágenes sintéticas

En este apartado, se presentan los resultados obtenidos de la segmentación de las imágenes sintéticas realizada con el objetivo de dividir las imágenes en las cuatro zonas consideradas como fondo. Para ello, como se explicó anteriormente, se lleva a cabo una reducción de dimensionalidad previa basada en PCA y, posteriormente, se utilizan las proyecciones sobre los tres primeros componentes principales para realizar la segmentación utilizando *K-means* o *Mean-shift*.

3.2.1. Principal Components Analysis. PCA

La figura 3.5 representa los resultados de aplicar el algoritmo PCA a los cuatro cubos hiperespectrales generados y a sus variantes con $\text{SNR} = 25$ dB y $\text{SNR} = 30$ dB. Se han representado los datos transformados sobre los tres primeros componentes principales, ya que, como se mostró anteriormente, los tres primeros componentes principales contienen la mayor parte de la información y permiten realizar la segmentación de las imágenes sin elevar de forma excesiva la carga computacional necesaria. Como puede comprobarse, se obtienen cinco nubes de puntos correspondientes a los cuatro materiales de fondo y a las anomalías, que permiten dividir la imagen en varias zonas utilizando los algoritmos de segmentación implementados.

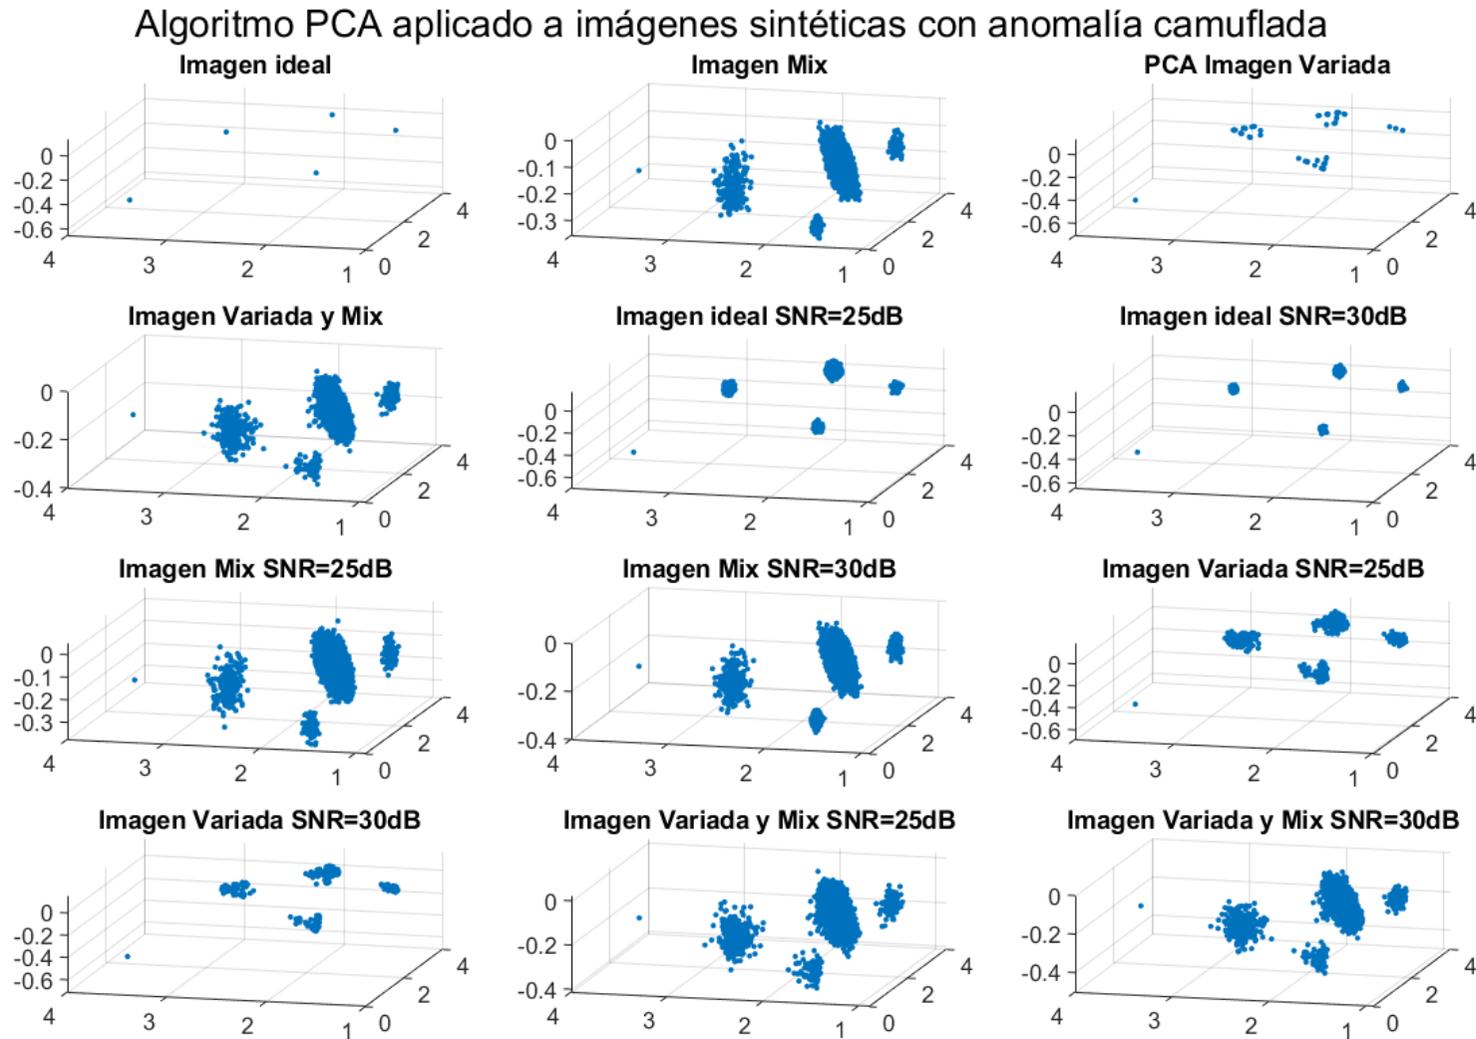
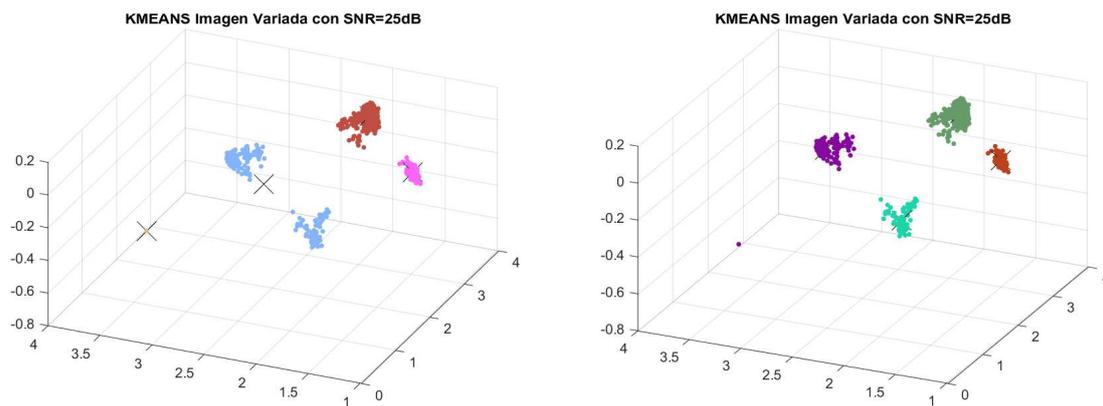


Figura 3.5: Resultados del algoritmo PCA aplicado a las imágenes sintéticas generadas. Se representan los datos proyectados sobre las tres primeras componentes principales, separándose en cinco nubes de puntos correspondientes a los cuatro materiales de fondo y a las anomalías, en los que debe segmentarse la imagen con los algoritmos de segmentación.

Resultados de K -means

En primer lugar, se evaluó el funcionamiento del algoritmo K -means aplicado sobre los datos hiperespectrales proyectados sobre los tres primeros componentes principales, que presenta como principal desventaja la necesidad de especificar a priori el número de clústers en los que se debe segmentar la imagen.

Especificando un valor $K = 4$, correspondiente a las cuatro zonas de fondo, se observó que en ciertos casos, como el representado en la Figura 3.6.a, la segmentación realizada no era adecuada, principalmente debido a la presencia de las anomalías y a la inicialización aleatoria utilizada en el algoritmo implementado. Por este motivo, para conseguir una segmentación adecuada, se configuró un valor de K más elevado ($K = 16$) y, una vez realizada la segmentación, se eliminaron los clústers con un número reducido de datos, que se consideran anomalías, y se fusionaron los clúster que se encuentran más cercanos hasta conseguir el número de grupos deseados (en este caso $K' = 4$). De esta forma, como se representa en la Figura 3.6.b, se obtiene la segmentación de la imagen en las cuatro zonas de fondo. Sin embargo, debido al inconveniente que supone la necesidad de especificar adecuadamente el parámetro K del algoritmo, especialmente para imágenes reales, se propuso utilizar el algoritmo $Mean-shift$ como alternativa.



(a) Segmentación no adecuada obtenida con K -means para $K = 4$ (b) Segmentación adecuada obtenida con K -means para $K = 16$ y fusión posterior de clústers próximos

Figura 3.6: Resultados obtenidos con algoritmo K -means aplicados a los datos hiperespectrales transformados sobre los tres primeros componentes principales (cada color representa un clúster obtenido con el algoritmo).

3.2.2. Mean-Shift

Resultados de $Mean-Shift$

La Figura 3.7 representa los resultados obtenidos con el algoritmo $Mean-shift$ implementado, que consigue segmentar adecuadamente todos los conjuntos de datos en las cuatro nubes consideradas como fondo de la imagen. Realmente, el algoritmo obtiene cinco clústers correspondientes a los cinco materiales de la imagen sintética (cuatro materiales de fondo y material

de los objetos camuflados), pero el clúster correspondiente a los objetos camuflados se elimina debido al número reducido de datos que contiene, indicación de que se tratan de anomalías. Este algoritmo no requiere especificar a priori el número de clústers, pero tiene como parámetro el radio de la ventana deslizante, que afecta al número de zonas en las que se divide la imagen. Por este motivo, se ha configurado dicho parámetro realizando pruebas hasta conseguir la separación adecuada de las nubes de puntos tanto en las imágenes sintéticas como en imágenes reales.

Además, aunque se observa que, si la nube de puntos de los objetos camuflados se separa de las nubes de puntos del fondo, los algoritmos de clustering pueden separar dichas anomalías, se ha implementado un algoritmo de detección de anomalías aplicado sobre todas las bandas espectrales medidas, ya que, en las imágenes reales, las nubes de puntos de las anomalías no son separables con los algoritmos de clustering implementados.

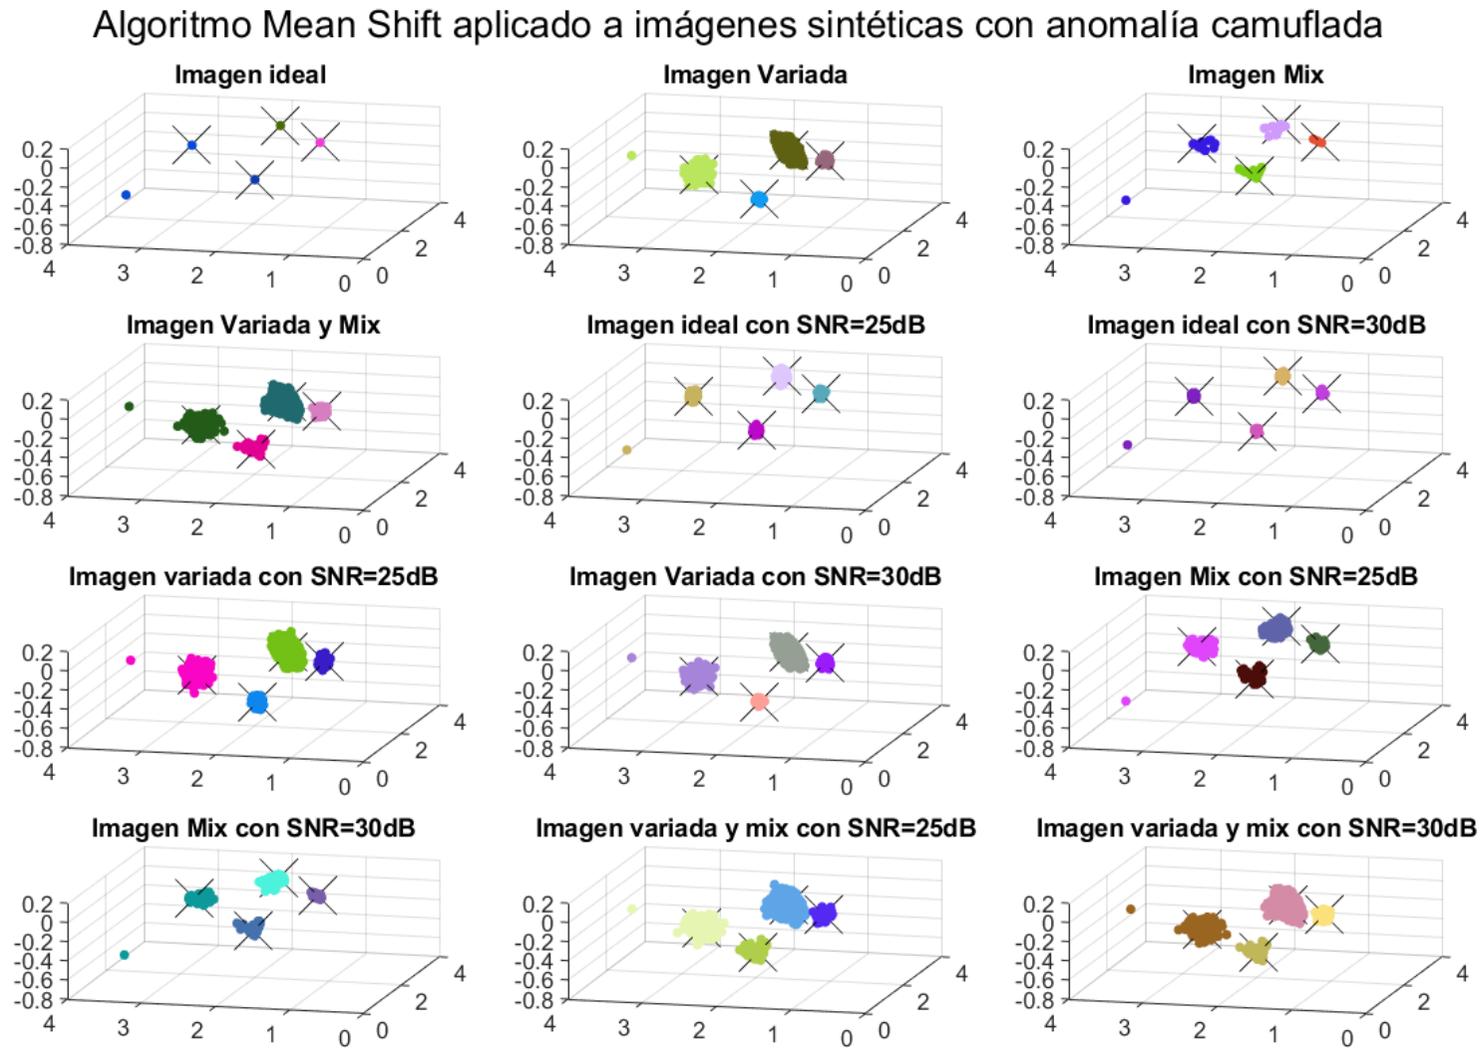


Figura 3.7: Resultados del algoritmo *Mean-Shift* aplicado a las imágenes sintéticas generadas (cada color representa un clúster obtenido del algoritmo).

3.3. Detección de anomalías en las imágenes sintéticas

Para llevar a cabo la detección de las anomalías en las imágenes hiperespectrales utilizando el algoritmo RX, se han implementado dos métodos para el cálculo de la media muestra y la matriz de covarianza de los datos de referencia. El primero de ellos consiste en utilizar los clústers obtenidos con el algoritmo de segmentación *Mean-shift* y utilizar para cada píxel bajo test la media y matriz de covarianzas calculadas para el clúster al que pertenece. El segundo método se basa en utilizar ventanas de referencia con celdas de guarda alrededor de cada píxel bajo test. Este segundo método presenta una mayor carga computacional debido a que requiere el cálculo de una matriz de covarianza de tamaño $B \times B$, siendo B el número de bandas espectrales medidas, y su inversa para cada píxel de la imagen. El primer método se indica en las imágenes de los resultados como **RX**, mientras que el segundo método se indica como **RX-Ventana**.

Para evaluar los resultados se presentan los resultados obtenidos al aplicar los algoritmos sobre tres de los conjuntos de datos simulados: (1) Imagen Variada con una SNR de 25dB, (2) Imagen Mix con una SNR de 25dB y (3) Imagen Variada y Mix con una SNR de 25dB. De esta forma, se incluyen los efectos de ruido de sensor, mezcla de firmas y variación aleatoria de las firmas respecto a la base de datos. Además, para seleccionar el umbral utilizado en el algoritmo RX para determinar la presencia de las anomalías, se han representado los histogramas de los valores RX obtenidos. En situaciones reales, se deberá seleccionar adecuadamente este umbral en función de la probabilidad de falsa alarma deseada o de la probabilidad de detección requerida de un determinado material sobre un determinado fondo.

Analizando los resultados obtenidos para la Imagen Variada (Figura 3.8) utilizando el método de segmentación previa (**RX**), se observa que la anomalía se detecta adecuadamente utilizando un umbral de $th_{RX} = 160$. En cambio, utilizando el mismo umbral para el método de ventana de referencia (**RX-Ventana**), se obtiene un mayor número de falsas alarmas. Ajustando dicho umbral, se consigue disminuir el número de falsas alarmas, pero estas se concentran en una zona de asfalto debido a que la ventana de referencia para esos píxeles contiene más zona de hierba que de asfalto. Este resultado pone de manifiesto uno de los problemas del método de ventana de referencia cuando se utiliza para imágenes con fondos no uniformes.

Por otro lado, la Figura 3.9 representa los resultados obtenidos para la Imagen Mix. Se observa que al mezclarse las firmas espectrales de los materiales en los bordes de las zonas, el algoritmo RX con segmentación previa da lugar a detecciones de anomalías en dichos bordes. Sin embargo, utilizando el método de ventana de referencia no se produce un aumento de las falsas alarmas en los bordes de los materiales. Sin embargo, las falsas alarmas debidas a mezcla de firmas espectrales podrán ser eliminadas en el posterior procesado de clasificación al realizar el *unmixing* y clasificar dos materiales que no corresponden con los objetos de interés.

Finalmente, en los resultados obtenidos con la Imagen Variada y Mix (Figura 3.10), se observan los mismos problemas que en los dos casos anteriores: las falsas alarmas en los bordes de las zonas para el método basado en la segmentación previa de la imagen y las falsas alarmas debidas a clutter no uniforme para el método basado en ventanas de referencia.

Por tanto, aunque con el algoritmo RX con segmentación previa se producen más falsas alarmas en los bordes de los materiales, se propone utilizar dicho método en lugar de emplear ventanas de referencia debido a la excesiva carga computacional que conllevan y a sus problemas en imágenes con fondos no homogéneos.

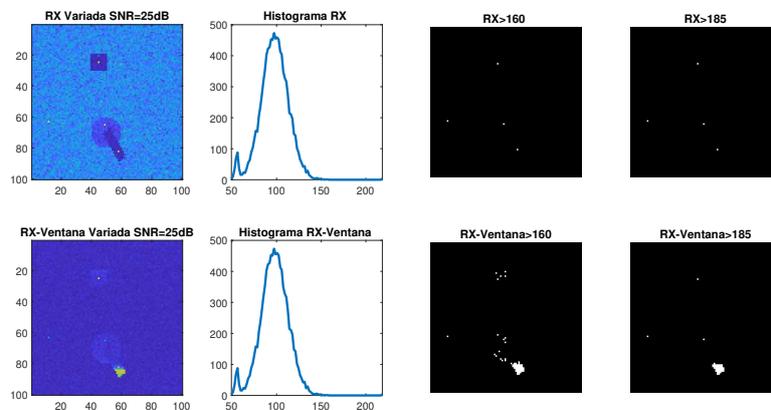


Figura 3.8: Algoritmo RX aplicado a la imagen con las firmas hiperespectrales variadas y una SNR de 25 dB.

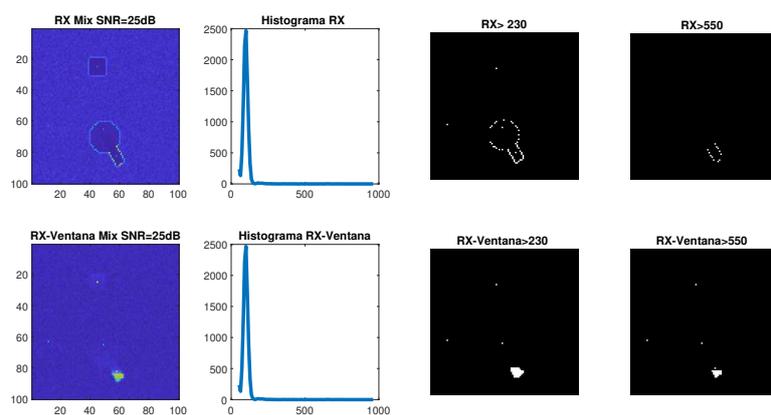


Figura 3.9: Algoritmo RX aplicado a la imagen con materiales mezclados en los bordes y una SNR de 25 dB .

Resultados obtenidos con baja SNR

Para comparar los resultados obtenidos con imágenes con poco y mucho ruido, y evaluar como se comporta el algoritmo implementado de detección de anomalías frente al ruido, se ha realizado el procesamiento de una imagen con baja SNR ($SNR = 5$ dB) y de otra imagen con alta SNR ($SNR = 30$ dB), representadas en la Figura 3.11, partiendo de la imagen ideal. Como puede observarse en la Figura 3.12, el algoritmo de segmentación *Mean-shift* aplicado a los datos transformados sobre los tres primeros componentes principales permite segmentar adecuadamente la imagen en las cuatro zonas correspondientes a los materiales considerados

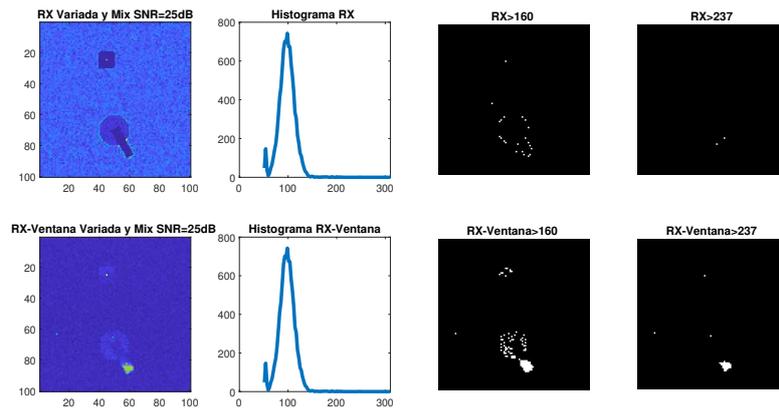


Figura 3.10: Algoritmo RX aplicado a la imagen con las firmas hiperespectrales variadas, materiales con los bordes mezclados y una SNR de 25 dB.

como fondo. El mayor ruido de la imagen con menor SNR da lugar a nubes de puntos más dispersas que pueden dar lugar a errores de segmentación.

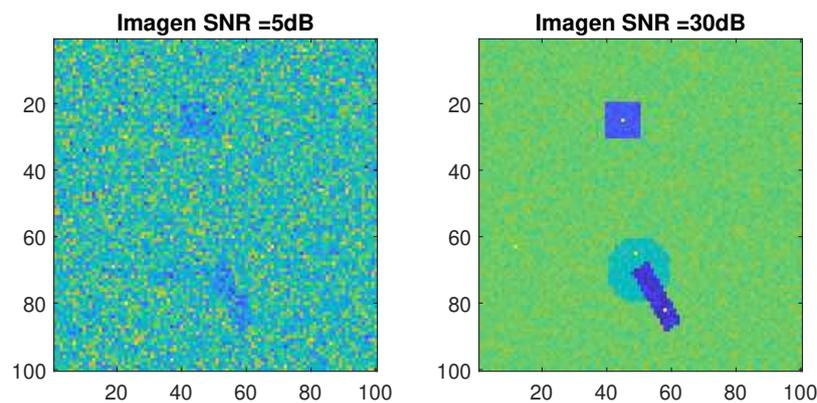


Figura 3.11: Reflectancia en la banda 50 ($1.36 \mu\text{m}$) de las imágenes hiperespectrales sintéticas generadas con $\text{SNR} = 5 \text{ dB}$ y $\text{SNR} = 30 \text{ dB}$

A su vez, en la Figura 3.13, se comprueba que debido a la disminución de SNR, al aplicar el algoritmo RX a una imagen con mucho ruido no se detectan adecuadamente las anomalías, teniendo que utilizar un umbral muy bajo que da lugar a un número excesivo de falsas alarmas, mientras que, en la imagen de alta SNR, se consiguen detectar las anomalías con baja probabilidad de falsa alarma. Aunque el algoritmo de clasificación permite disminuir el número de falsas alarmas globales de la cadena de procesado, filtrando aquellas anomalías que no correspondan con materiales de interés, el mayor número de falsas alarmas en la etapa de detección de anomalías supone un aumento de carga computacional en la etapa de clasificación, al tener que aplicarse los algoritmos basados en *sparse regression* a un mayor número de píxeles.

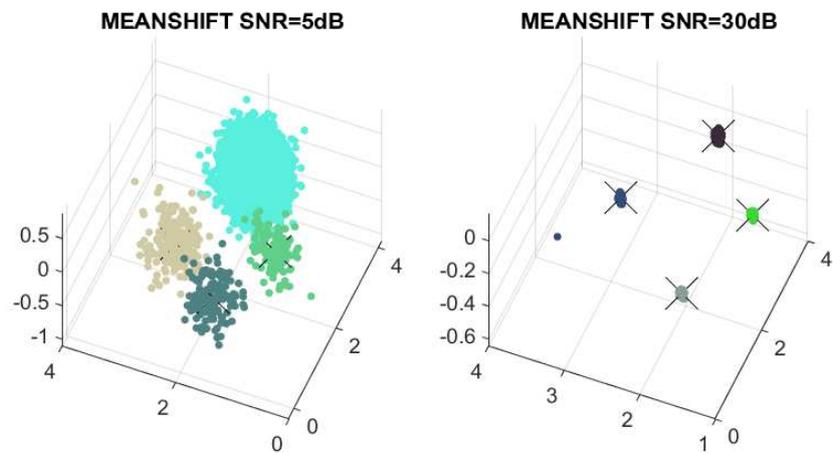


Figura 3.12: Resultados del algoritmo *Mean-shift* aplicado sobre dos imágenes sintéticas con $\text{SNR} = 5 \text{ dB}$ y $\text{SNR} = 30 \text{ dB}$, respectivamente, para comprobar el comportamiento de los algoritmos frente a ruido.

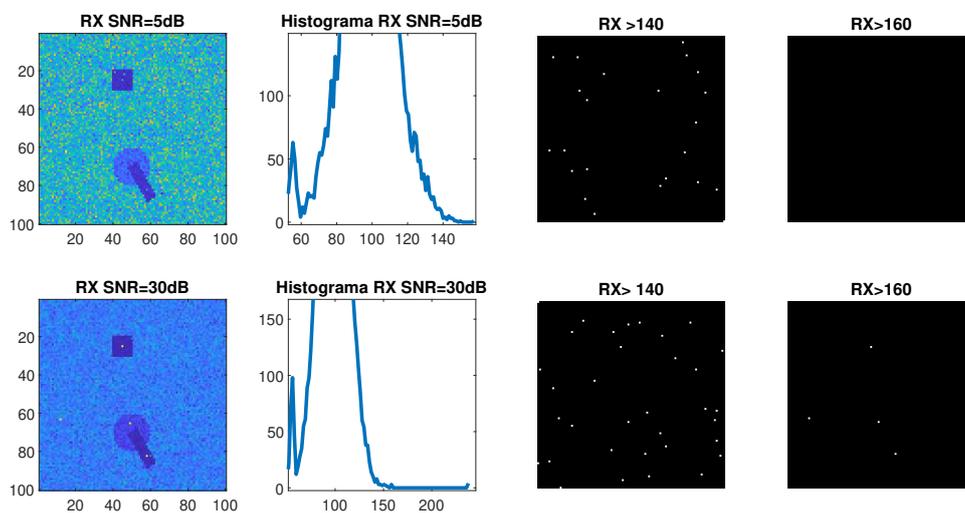


Figura 3.13: Resultados del algoritmos RX aplicado sobre dos imágenes sintéticas con $\text{SNR} = 5 \text{ dB}$ y $\text{SNR} = 30 \text{ dB}$, respectivamente, para comprobar el comportamiento de los algoritmos frente a ruido.

3.4. Clasificación de anomalías en las imágenes sintéticas

En este apartado se ha realizado la clasificación de algunas de las anomalías detectadas anteriormente y se ha evaluado la robustez del algoritmo frente a mezclas y ruido. En primer lugar se ha cogido cuatro píxeles de la imagen ideal y un píxel de anomalía, correspondientes a los cuatro materiales para clasificarlos. Después se ha clasificado un píxel correspondiente a la imagen ideal con los bordes entre materiales mezclados, para evaluar la robustez del algoritmo frente a píxeles no puros. Tras esto se ha evaluado la robustez del algoritmo frente a diferentes valores de SNR. Por último se puede observar un mapa con las abundancias correspondientes a los cinco materiales usados en una imagen con un porcentaje pequeño de ruido.

Clasificación firmas hiperespectrales en píxeles puros y mezcla

En este apartado, se ha realizado la clasificación de algunas de las anomalías detectadas anteriormente mediante el algoritmo basado en *sparse regression* y se ha evaluado su robustez frente a mezclas espectrales y ruido. En primer lugar, se han analizado cuatro píxeles de la imagen ideal, correspondientes a los cuatro materiales de fondo, y un píxel de anomalía. Posteriormente, se ha aplicado el algoritmo de clasificación a píxeles con mezcla espectral en los bordes de las zonas, que daban lugar a anomalías con el algoritmo RX, para comprobar el funcionamiento del algoritmo en píxeles no puros. Tras esto, se ha evaluado la robustez del algoritmo frente a diferentes niveles de SNR. Por último, se presenta el mapa de materiales más abundantes en cada píxel obtenido para la imagen hiperespectral completa con una SNR alta.

Clasificación de firmas hiperespectrales en píxeles puros y con mezcla

En la figura 3.14, se observa la clasificación de cuatro píxeles escogidos de la imagen ideal, correspondientes a los cuatro materiales utilizados para generar el fondo de las imágenes sintéticas. De esta forma, se comprueba que el algoritmo basado en *sparse regression* consigue clasificar correctamente las firmas en ausencia de ruido y variaciones aleatorias de las firmas espectrales respecto de la base de datos. Sin embargo, a pesar de tratarse de una situación ideal, en general, no obtiene como resultado una abundancia del 100 % para cada material, debido a la similitud entre distintas firmas contenidas en la base de datos, como, por ejemplo, *Oak* y *Pine*. Por otro lado, en la figura 3.15, se representa la clasificación obtenida de un píxel de anomalía, llegando a la misma conclusión que con el resto de materiales.

A su vez, se ha procesado un píxel del borde entre los materiales Arena y Hierba que presenta una mezcla espectral de ambos materiales para evaluar el comportamiento frente a píxeles con mezcla. En la Figura 3.16, se representa el resultado obtenido, observándose que se clasifican los dos materiales de la mezcla, pero que aparecen además otros materiales erróneos con menor abundancia que podrían llevar a confusión. Estos resultados ponen de manifiesto la dificultad de obtener un funcionamiento adecuado de los algoritmos de clasificación incluso en escenarios más simples que las imágenes reales. Por tanto, es importante la calidad y la selección de la base de datos espectral de los materiales, así como el ajuste de los parámetros del algoritmo de clasificación.

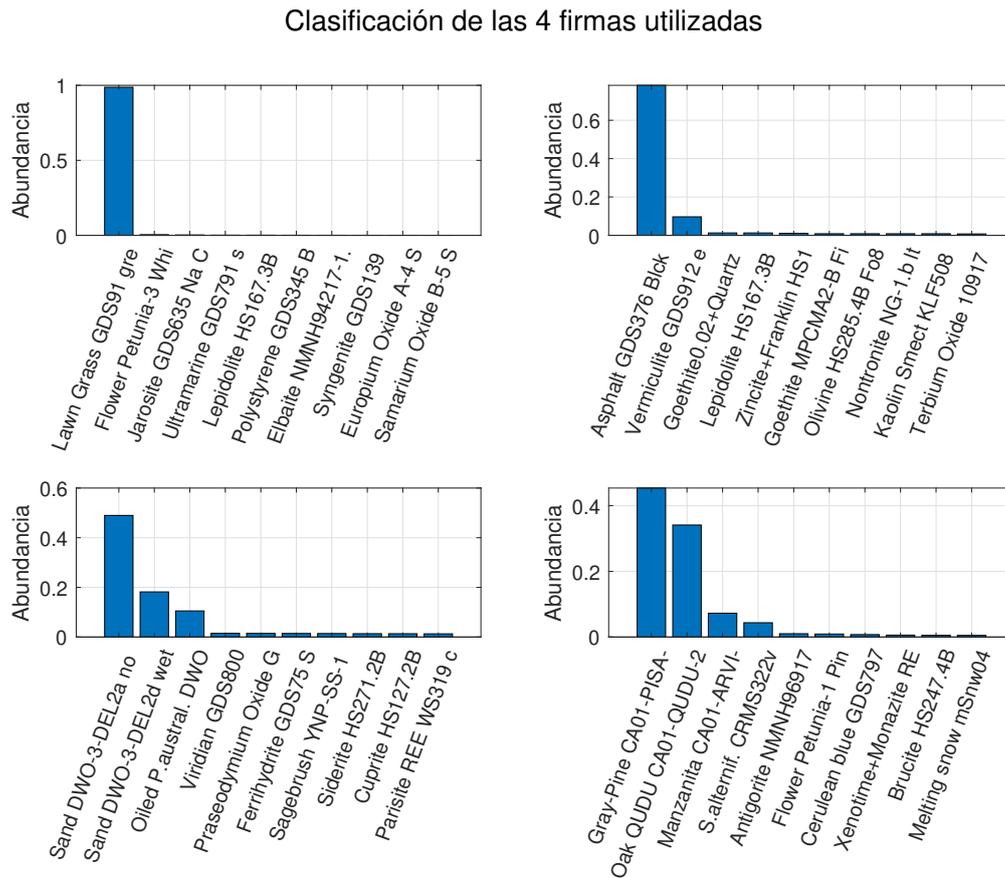


Figura 3.14: Clasificación de los espectros de cuatro píxeles correspondientes a los cuatro materiales de fondo de la imagen ideal: hierba, arena, pino y asfalto.

Evaluación de la robustez del algoritmo frente a diferentes valores de SNR

A continuación, se ha analizado la variación de la abundancia detectada para un píxel de material Hierba en función de la SNR de la imagen. En la Figura 3.17, se observa que a medida que la SNR de la imagen aumenta, la abundancia del material detectado (que debe ser idealmente 1) también lo hace. Por tanto, se observa que el algoritmo de clasificación es poco robusto al ruido y, con SNR por debajo de 40 dB, no consigue clasificar adecuadamente las firmas espectrales, dando lugar a clasificaciones erróneas que pueden producir falsas alarmas o la pérdida de detecciones en imágenes con baja SNR o con respuestas espectrales de los materiales significativamente distintas a las contenidas en la base de datos. Sin embargo, al no requerir una clasificación detallada de los materiales, los errores que más impactan en el correcto desempeño del algoritmo para la aplicación considerada son los que suponen un error en la clasificación del tipo (vegetación, mineral, metal, plásticos, etc.) de material.

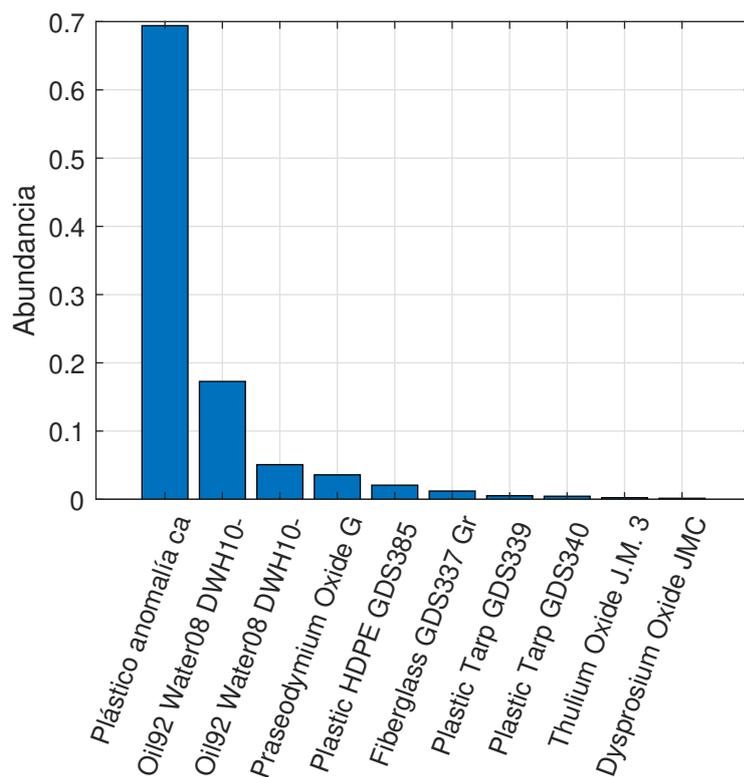


Figura 3.15: Clasificación de un píxel de plástico (anomalía introducida) del cubo hiperespectral generado para la imagen ideal.

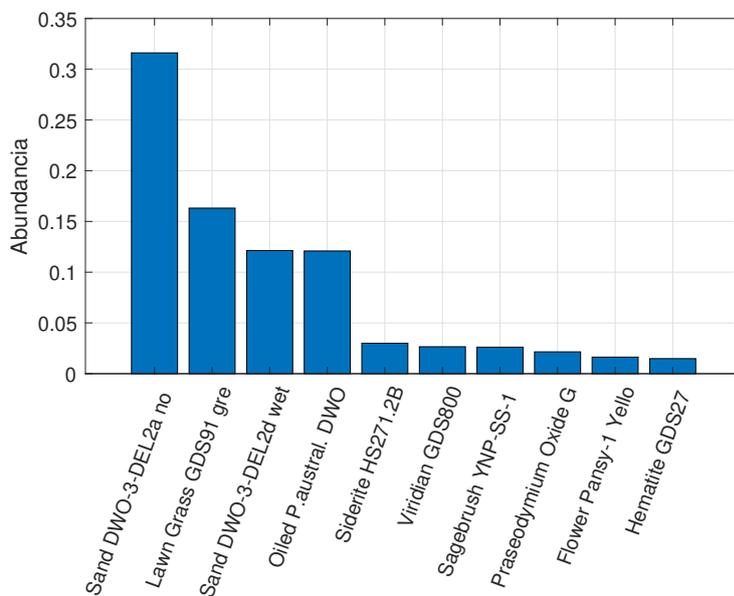


Figura 3.16: Clasificación de un píxel escogido en el borde mezclado entre la Arena y la Hierba sin considerar ruido ni variaciones aleatorias de las firmas espectrales respecto a la base de datos.

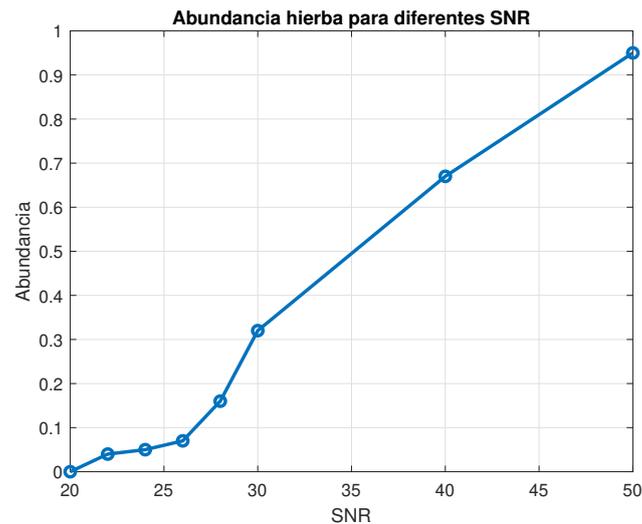


Figura 3.17: Abundancia obtenida para un píxel de hierba en función de la SNR de la imagen.

Mapa de materiales más abundates en una imagen sintética con SNR alta

La Figura 3.18 representa el material más abundante en cada píxel que se ha obtenido aplicando el algoritmo de clasificación a un cubo hiperespectral con una SNR alta de 50 dB. Como puede observarse, en general, los píxeles se clasifican adecuadamente, excepto algunos píxeles de *Pine* que se clasifican como *Oak*, debido a la similitud entre ambas firmas hiperespectrales. Sin embargo, como se comentó anteriormente, este tipo de errores, al ser los dos materiales de tipo vegetación, no impacta en el desempeño del procesado para la aplicación considerada, al no requerir normalmente una clasificación detallada del material sino una clasificación más general del tipo de material.

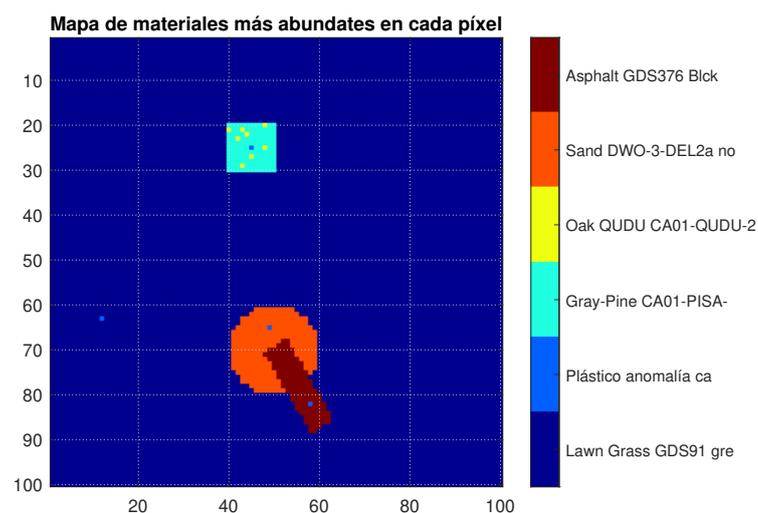


Figura 3.18: Mapa de abundancias de la imagen ideal hiperespectral completa, con SNR de 50dB.

Capítulo 4

Procesamiento de imágenes hiperespectrales y multiespectrales reales

En este capítulo, se aplica la cadena de procesado propuesta en el Capítulo 2 para la detección y clasificación de anomalías, cuyo funcionamiento se ha evaluado utilizando imágenes hiperespectrales en el Capítulo 3, a imágenes hiperespectrales reales obtenidas de un dataset de imágenes del sensor AVIRIS y a imágenes multiespectrales obtenidas del satélite Sentinel-2. Como era de esperar, los resultados obtenidos con las imágenes multiespectrales del Sentinel-2, que presentan 13 bandas espectrales, son significativamente peores a los obtenidos con las imágenes hiperespectrales del AVIRIS y HYDICE, que presentan más de 200 bandas espectrales.

4.1. Procesamiento de imágenes hiperespectrales del sensor AVIRIS y HYDICE

Se ha aplicado la cadena de procesado implementada a un conjunto de 12 imágenes hiperespectrales capturadas con el sensor AVIRIS de un dataset para evaluar algoritmos de detección de anomalías [6]. Como se observa en la Figura 4.1, 4 conjuntos de datos pertenecen a aeropuertos, 4 conjuntos a un escenario de playa y otros 4 a zonas urbanas. De todas las bandas espectrales capturadas por los sensores AVIRIS y HYDICE, se eliminan aquellas bandas afectadas por la absorción atmosférica, que presentan una baja SNR.

4.1.1. Resultados de la etapa de segmentación

Como se ha descrito anteriormente, en la cadena de procesado se lleva a cabo la segmentación de las imágenes hiperespectrales utilizando el algoritmo *Mean-shift* tras aplicar el algoritmo PCA para reducir la dimensionalidad de los datos, que, en este caso, presentan más de 200 bandas espectrales, y reducir la carga computacional. En la Figura 4.1, se presentan los resultados obtenidos de la segmentación de las nubes de puntos de las imágenes del dataset transformados sobre los tres primeros componentes principales.

Como puede observarse, a diferencia de las imágenes sintéticas, las imágenes reales presentan nubes de puntos más difícilmente separables con los algoritmos de segmentación. De hecho, en algunos conjuntos de datos se obtiene un único clúster debido a que presentan un fondo predominante bastante homogéneo, mientras que, en otros conjuntos, se obtienen dos clústers.

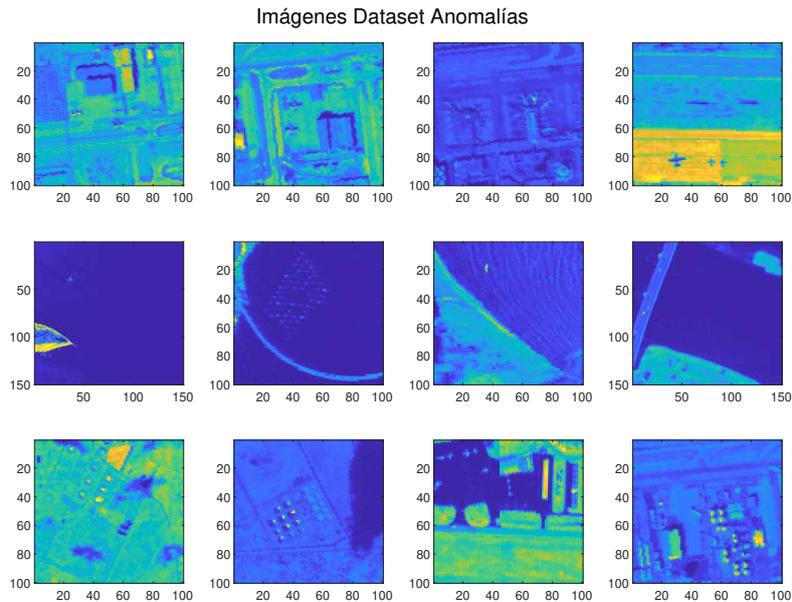


Figura 4.1: Corte del cubo hiperespectral del dataset de AVIRIS para evaluar el procesado implementado. Las imágenes de la primera fila corresponden a aeropuertos, la segunda fila a playas y la tercera a zonas urbanas.

Para realizar una segmentación más fina, se analizó la posibilidad de reducir el radio de la ventana deslizante del algoritmo *Mean-shift*, pero la sobresegmentación de la imagen dio lugar a un peor desempeño del algoritmo de detección de anomalías, especialmente en imágenes con fondos uniformes, ya que se producía un auto-ocultamiento de las mismas al formar parte de clústers con menor número de píxeles de fondo que presentaban una media más próxima a los espectros de las anomalías. De esta forma, se puso de manifiesto la necesidad de seleccionar adecuadamente el parámetro de radio de las ventanas deslizantes del algoritmo *Mean-shift*.

4.1.2. Resultados de la etapa de detección de anomalías

Utilizando las imágenes reales del dataset con anomalías, se analizó el comportamiento del algoritmo RX utilizando las dos variantes implementadas para el cálculo de la media y matriz de covarianzas muestrales, obteniendo los resultados presentados en las Figuras 4.3 y 4.4 para el algoritmo RX con segmentación previa y las Figuras 4.5 y 4.6 para el algoritmo RX con ventana de referencia. Como puede observarse, en todas las imágenes se detectan bastantes anomalías correspondientes a elementos de la escena que no corresponden con el fondo de la imagen, como aviones o determinadas infraestructuras. Además, no se observan diferencias apreciables en los resultados obtenidos con los dos métodos evaluados, por lo que se justifica el empleo de la segmentación previa con el objetivo de reducir la carga computacional de la cadena de procesado completa.

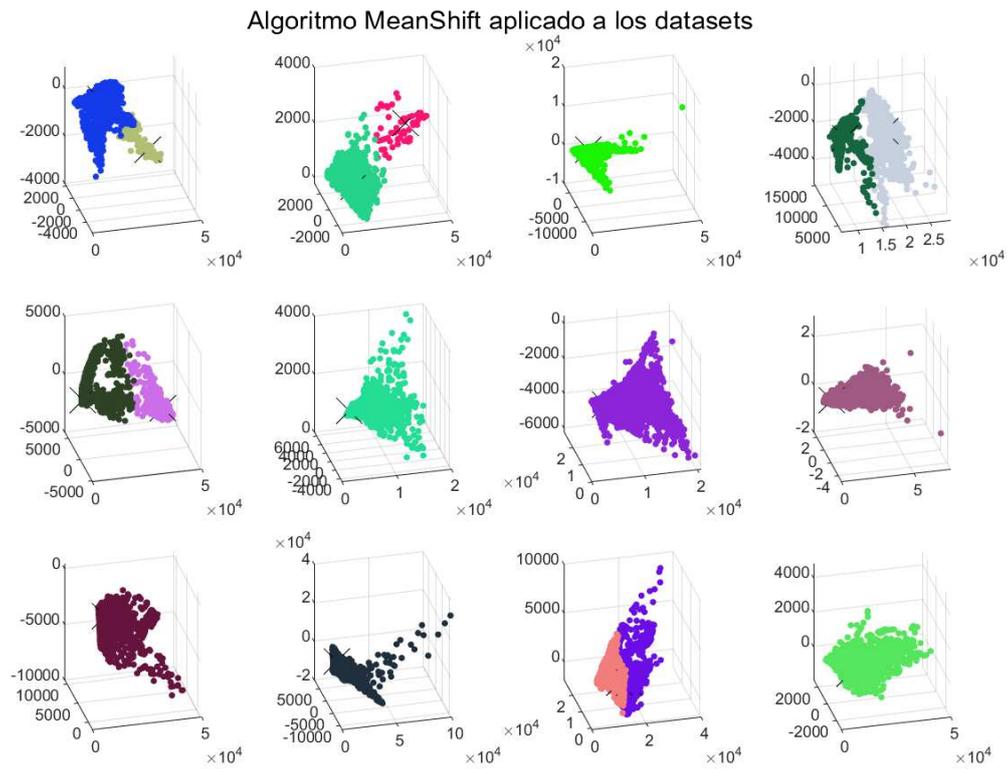


Figura 4.2: Resultados del algoritmo *Mean-shift* aplicado a las imágenes con anomalías del datasets de AVIRIS y HYDICE (cada color representa un clúster).

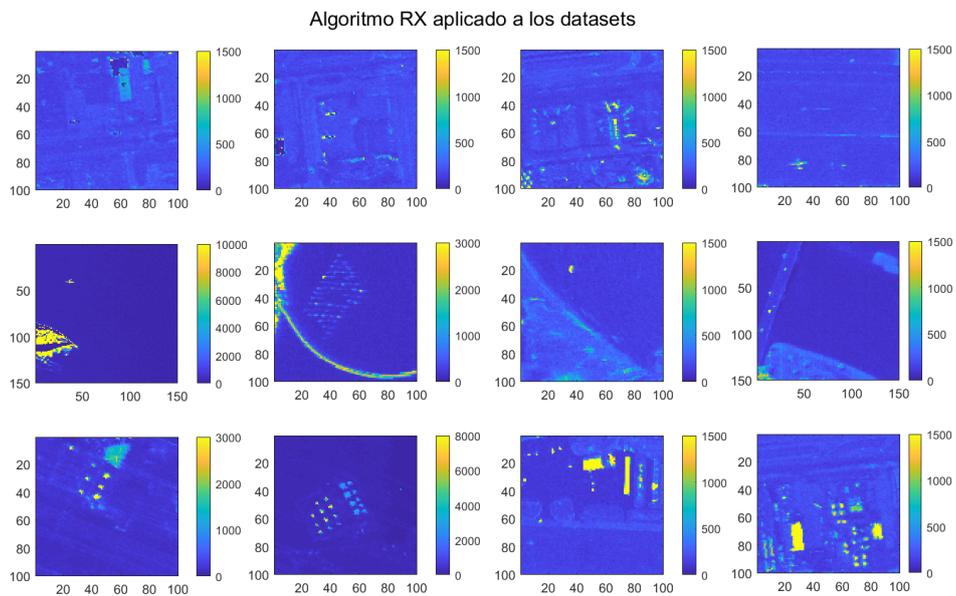


Figura 4.3: Resultado del algoritmo RX con segmentación previa antes de umbralizar aplicado a imágenes hiperespectrales reales.

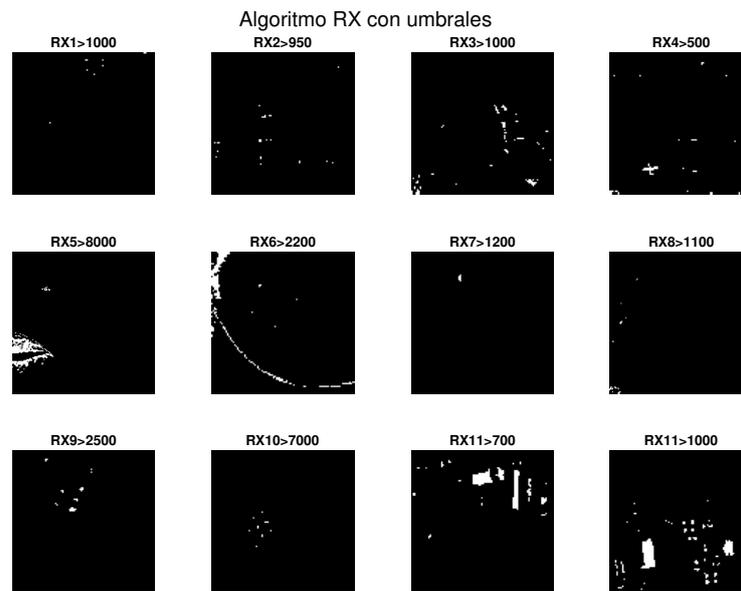


Figura 4.4: Resultados umbralizados del algoritmo RX con segmentación previa, en los que se observan las anomalías detectadas.

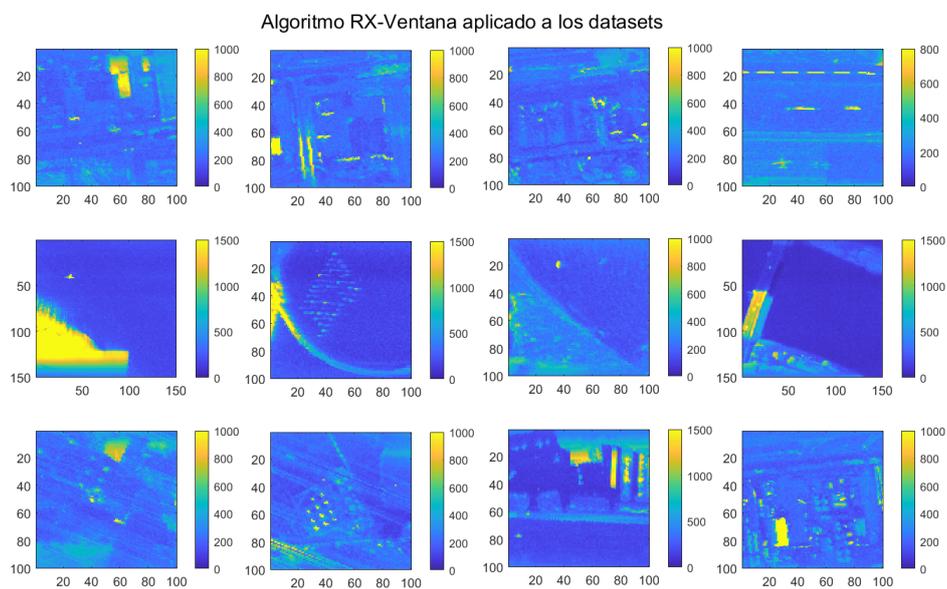


Figura 4.5: Resultado del algoritmo RX con ventana de referencia antes de umbralizar aplicado a imágenes hiperespectrales reales.

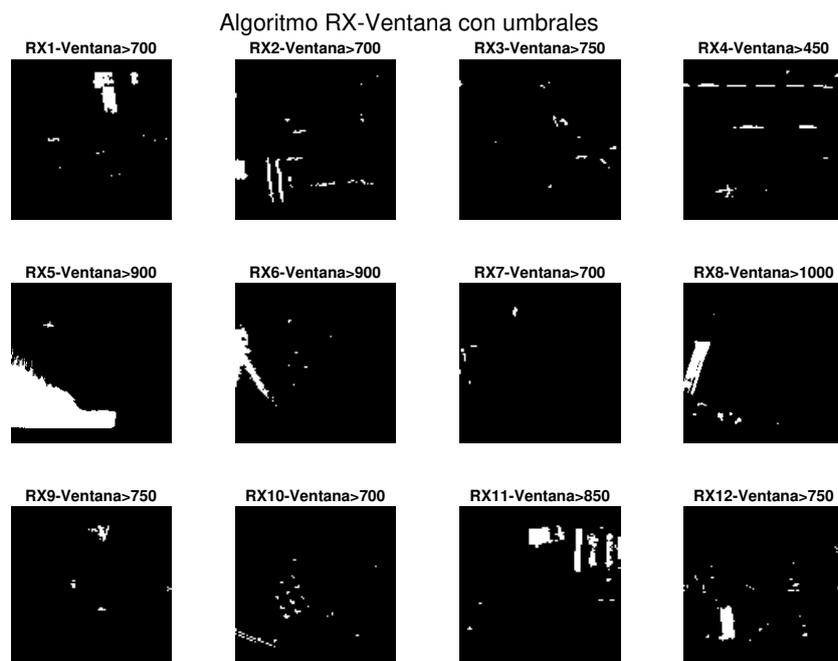


Figura 4.6: Resultados umbralizados del algoritmo RX con ventana de referencia, en los que se observan las anomalías detectadas.

4.1.3. Clasificación en el dataset

En esta sección, se ha aplicado el algoritmo de clasificación a dos de las imágenes del dataset representado en la Figura 4.1, correspondientes a un aeropuerto (imagen de la primera fila y cuarta columna) y a una playa (imagen de la segunda fila y primera columna)

Clasificación de la imagen del aeropuerto

En la Figura 4.7, se observan los mapas de abundancias de los cuatro materiales más abundantes globalmente obtenidos en la clasificación de las anomalías de la imagen del aeropuerto. Se puede ver que estos materiales son :*Epsomite GDS149*, *Mascagnite GDS65.a*, *Ulexite GDS138 Boron y Ammoniu, Chloride GD*. Por otro parte, en la figura ??, se representa el mapa de materiales más abundantes en cada píxel de anomalía de la imagen. Como puede observarse, en los píxeles correspondientes al avión, se detecta como material más abundante la Epsomita, que se trata de un mineral de color blanco, pero que no se corresponde con el material del avión. Este resultado pone de manifiesto la dificultad de la clasificación correcta de los materiales en imágenes reales.

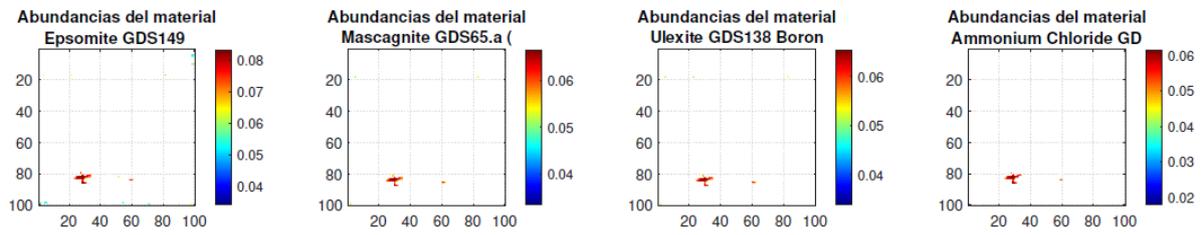


Figura 4.7: Mapas de abundancias de los cuatro materiales más abundantes en las anomalías detectadas del dataset del aeropuerto.

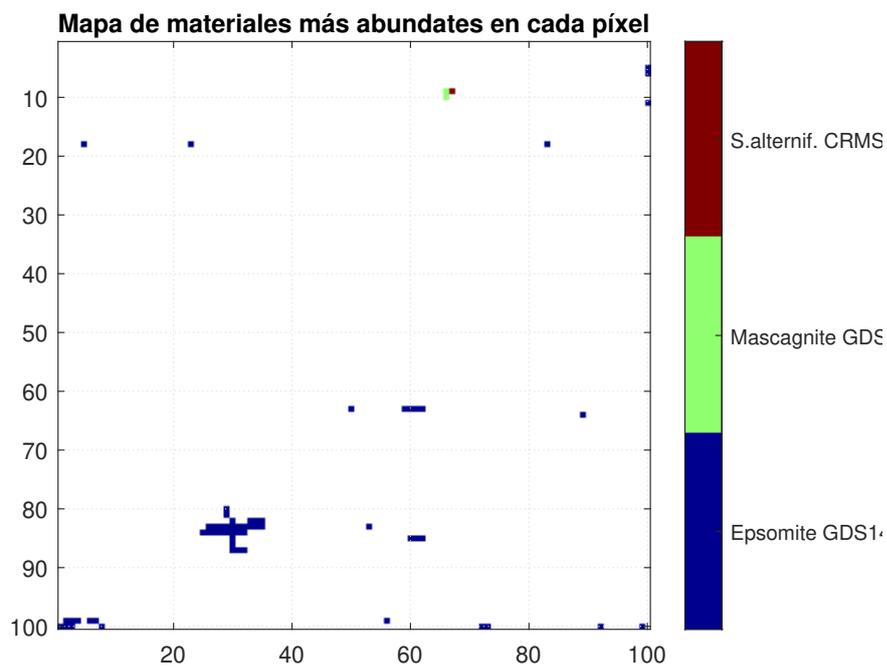


Figura 4.8: Mapa de materiales más abundantes en cada píxel de anomalía en el dataset del aeropuerto.

Clasificación de la imagen de la Playa

De igual modo, la figura 4.9 representa los mapas de abundancias para los cuatro materiales más abundantes globalmente en la imagen de la playa obtenidos con el algoritmo de clasificación implementado. En este caso, los materiales más abundantes son : *Melting snow mnSnw04*, *Melting snow mSnw14*, *Mascagnite GDS65* y *Epsomite GDS149*. En este caso, obtener como materiales más abundantes "Nieve" podría justificarse por la presencia de suelo mojado en la zona donde se detectan las anomalías. A su vez, la Figura 4.10 representa el mapa de materiales más abundates en cada píxel de la imagen. Estos resultados muestran igualmente la dificultad de realizar la clasificación de los materiales en imágenes hiperespectrales, y la necesidad de desarrollar algoritmo más robustos y precisos en imagenes reales y bases de datos más apropiadas para la clasificación espectral de materiales.

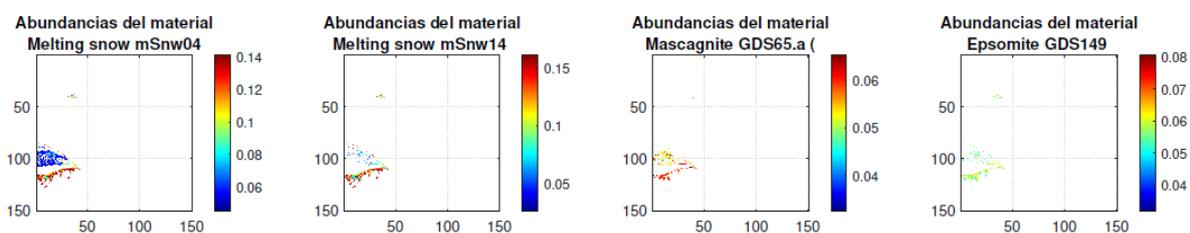


Figura 4.9: Clasificación de los cuatro materiales más abundantes en las anomalías detectadas pertenecientes al dataset del playa

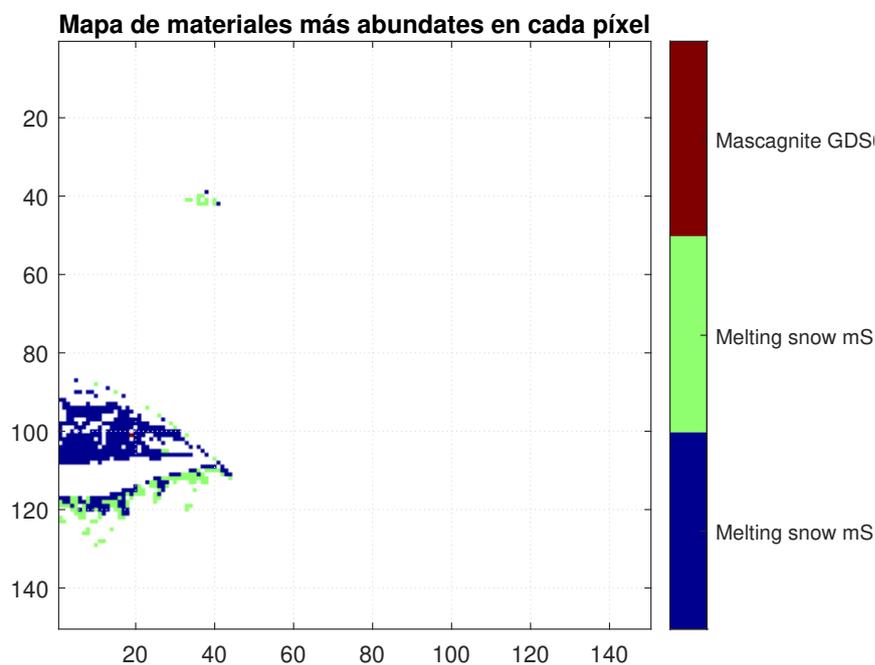


Figura 4.10: Mapa de abundancias de las anomalías detectadas en el dataset de la playa

4.2. Procesamiento Sentinel

A continuación, se presentan los resultados obtenidos al aplicar el procesamiento a una imagen multiespectral tomada con el satélite Sentinel-2 con 13 bandas espectrales. Para ello, se seleccionó de la base de datos públicos del Sentinel-2 [7] una imagen, representada en la Figura 4.11 en RGB, que presentara elementos que pudieran ser considerados como anomalías. Como puede observarse, la imagen seleccionada presenta zonas con placas solares que pueden ser detectadas gracias a las diferencias que presenta respecto de los materiales de sus alrededores (tierra, vegetación, etc.).

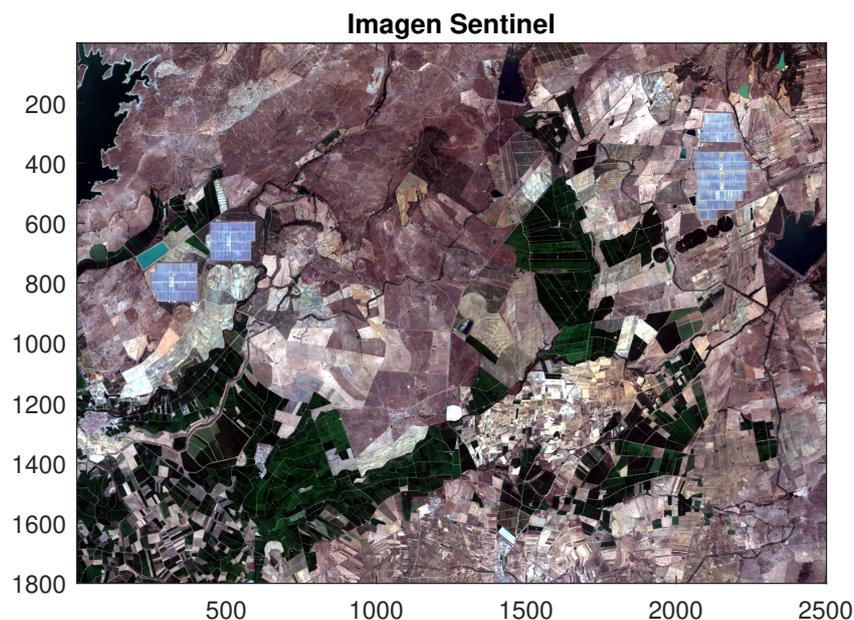


Figura 4.11: Imagen RGB de la imagen multiespectral seleccionada del Sentinel-2 para evaluar los resultados del procesamiento de una imagen real multiespectral con anomalías (placas solares) [7].

4.2.1. Segmentación de la imagen multiespectral

La Figura 4.12 representa el resultado de aplicar el algoritmo PCA a la imagen multiespectral. Como ocurría con las imágenes hiperespectrales reales procesadas anteriormente, se obtiene una nube de puntos sin grupos claramente separados. A su vez, los resultados obtenidos con el algoritmo *Mean-shift* utilizando dos valores distintos del radio de la ventana deslizante se muestran en las Figuras 4.13 y 4.14. Como puede observarse, cuanto menor es el radio seleccionado, mayor es el número de clúster que se obtienen. Sin embargo, como se comentó anteriormente, una sobsegmentación puede dar lugar al ocultamiento de las anomalías utilizando el algoritmo RX, efecto que se muestra en los resultados de dicho algoritmo utilizando las dos segmentaciones realizadas.

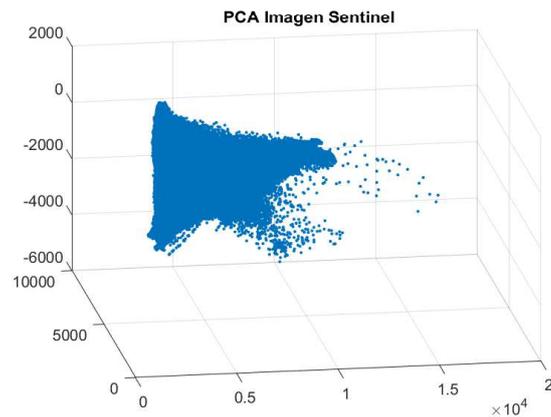
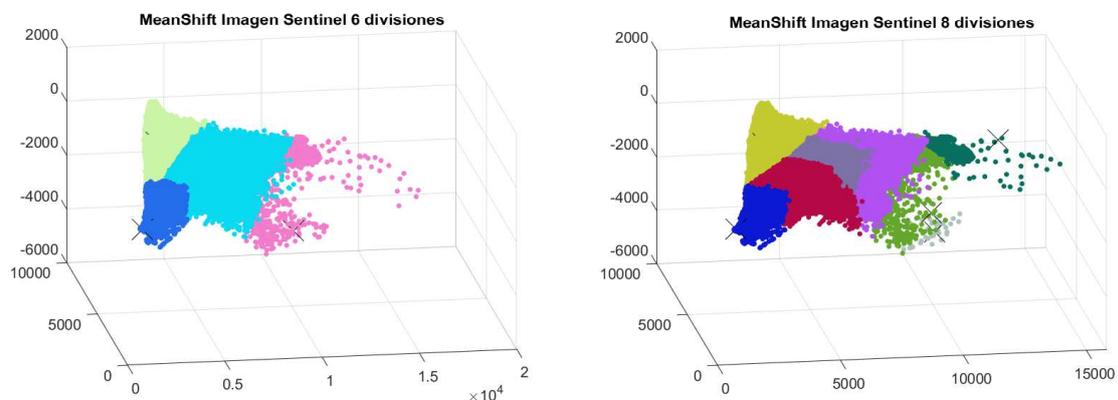


Figura 4.12: Algoritmo PCA aplicado a la imagen multispectral del Sentinel-2.



(a) Resultados con un mayor radio de la ventana deslizando obteniéndose 4 clústers (b) Resultados con un menor radio de la ventana deslizando obteniéndose 7 clústers

Figura 4.13: Resultados del algoritmo *Mean-shift* aplicado a la imagen multispectral del Sentinel-2 utilizando dos radios distintos de la ventana de asignación (cada color corresponde a un clúster).

4.2.2. Detección de anomalías en la imagen multispectral

En la Figura 4.15, se representan los resultados obtenidos del algoritmo RX utilizando las dos segmentaciones realizadas previamente de la imagen multispectral. Como puede observarse, la segmentación con menor número de clúster permite la detección de las placas solares, consideradas como anomalías de la imagen, mientras que la sobresegmentación da lugar a su ocultamiento. Por tanto, se pone de manifiesto la necesidad de seleccionar adecuadamente los parámetros del algoritmo de segmentación, para evitar que se produzca una división excesivamente fina que dé lugar al ocultamiento de las anomalías. Además, se detectan otras anomalías debidas a distintos elementos presentes en la imagen y en los bordes de las zonas, que pueden considerarse falsas alarmas y que deberían eliminarse en el proceso de clasificación si no corresponden con los materiales de interés de los objetos ocultos o de los blancos que se desean detectar. No obstante, aunque la clasificación no sea muy exacta, puede dar una idea del tipo de material que tienes.

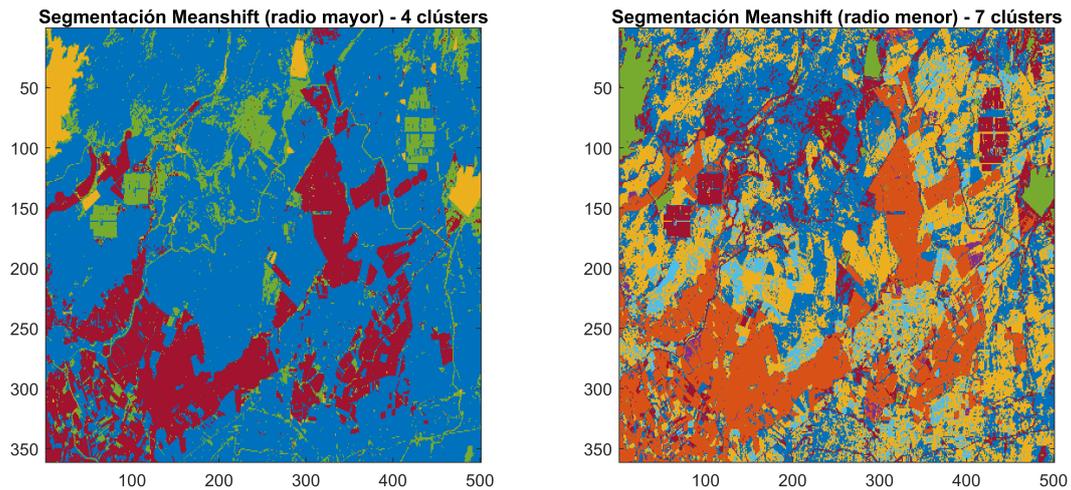
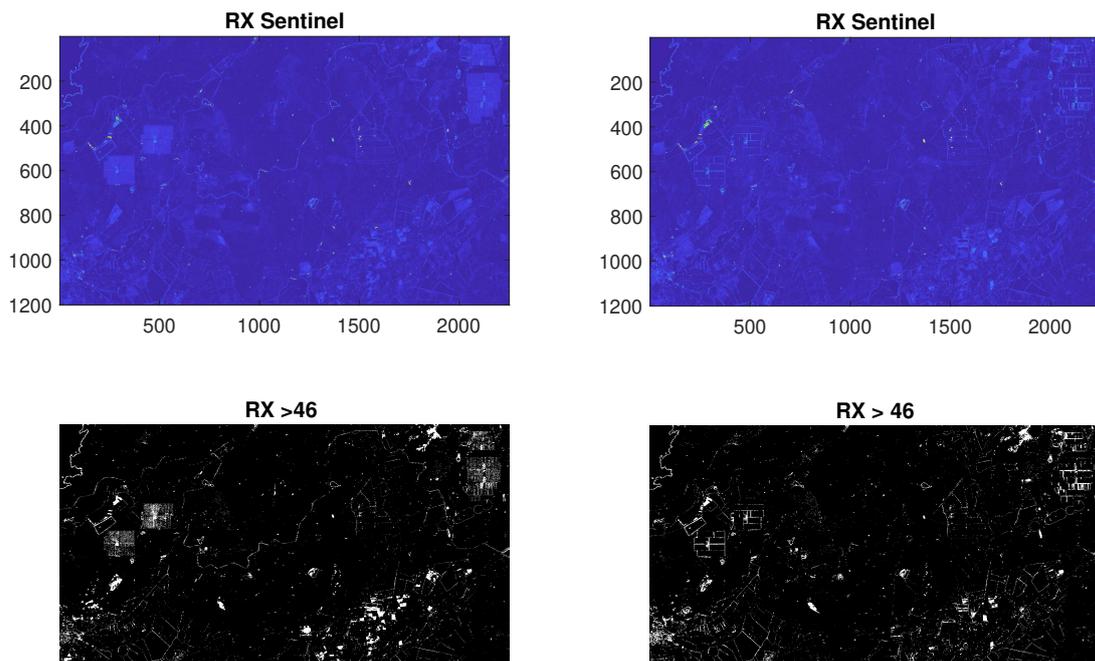


Figura 4.14: Imagen segmentada del Sentinel-2 con el algoritmo *Mean-shift* para dos valores distintos del radio de la ventana deslizante (cada color corresponde a un clúster).

4.2.3. Clasificación en Sentinel

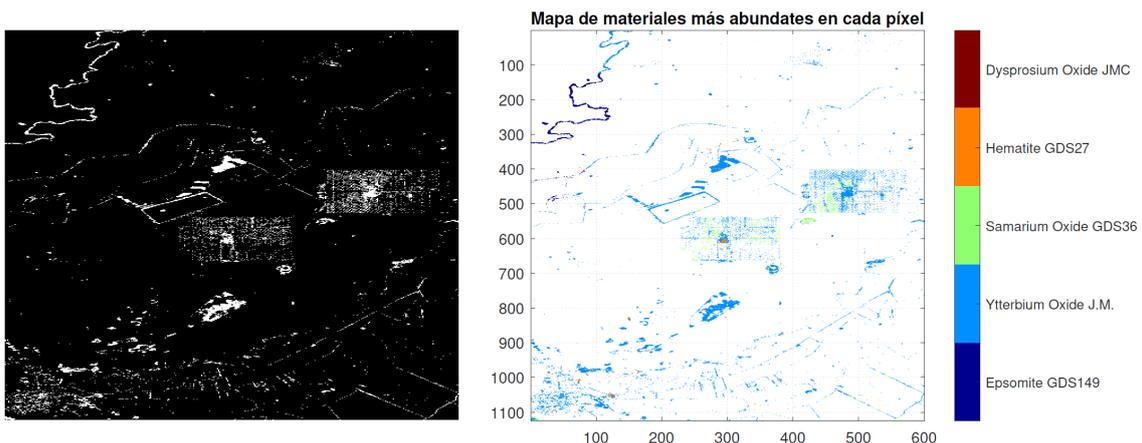
Finalmente, se ha realizado la clasificación de las anomalías detectadas en una sección de la imagen multiespectral considerada del Sentinel-2, que incluye una zona en la que se encuentran las placas solares observadas en la Figura 4.11. Las anomalías detectadas en dicha sección se representan en la Figura 4.16.a, donde se observan las placas solares detectadas. A su vez, la Figura 4.16.a representa el mapa de materiales más abundantes en cada píxel generado con el algoritmo de clasificación, dando lugar a la detección de distintos materiales minerales, aunque no se corresponden exactamente con los materiales reales.



(a) Resultados de RX con segmentación en cuatro clústers

(b) Resultados de RX con segmentación en siete clústers

Figura 4.15: Resultados del algoritmo RX aplicado a la imagen multispectral del Sentinel-2 segmentada con *Mean-shift* utilizando dos radios de la ventana deslizante que dan lugar a segmentaciones en 4 o 7 clústers, respectivamente.



(a) Anomalías detectadas en la sección considerada de la imagen del Sentinel-2 utilizando la segmentación con cuatro clústers

(b) Mapa de materiales más abundantes en cada píxel obtenido con el algoritmo de clasificación en la sección considerada de la imagen del Sentinel-2

Figura 4.16: Resultados del algoritmo de clasificación aplicado a una sección de la imagen del Sentinel-2 que contiene una zona con placas solares.

Capítulo 5

Lineas futuras y 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, destaca la posibilidad de detectar objetos camuflados ópticamente al ojo humano utilizando imágenes hiperespectrales. Este tema es objeto de investigación en el campo de la teledetección, en el que se enmarca este trabajo fin de grado, cuyo objetivo principal ha sido el desarrollo de 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. Se han evaluado dos métodos para el cálculo de la media y matriz de covarianza muestrales de los datos de referencia que se utilizan en el algoritmo RX: (1) emplear los clústers obtenidos en la etapa de segmentación para calcular una media y matriz de covarianza para cada clúster, y (2) utilizar una ventana de referencia con celdas de guarda alrededor de la celda bajo test. Aunque el método basado en la segmentación de la imagen da lugar a falsas alarmas en los bordes de las zonas con mezcla de firmas espectrales, su menor carga computacional justifica su empleo respecto al método basado en ventanas de referencia. Por último, la clasificación de las anomalías detectadas en las imágenes 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.

Las capacidades de estos algoritmos se han evaluado utilizando, en primer lugar, imágenes hiperespectrales sintéticas generadas en MATLAB a partir de firmas de una base de datos,

que incluyen distintos efectos que degradan la calidad de la imagen: ruido de adquisición para diferentes SNRs, variaciones aleatorias de las firmas espectrales respecto de la base de datos y mezclas de firmas espectrales en los bordes de las zonas. Finalmente, se aplicó la cadena de procesamiento a imágenes hiperespectrales y multiespectrales reales, observándose, en general, mejores resultados en las imágenes hiperespectrales capturadas por los sensores AVIRIS y HYDICE que en las imágenes multiespectrales adquiridas por el satélite Sentinel-2. Sin embargo, los resultados obtenidos de la clasificación en imágenes reales ponen de manifiesto la dificultad de realizar una clasificación precisa de los materiales y la necesidad de desarrollar algoritmos más robustos y bases de datos más apropiadas para la clasificación espectral de materiales.

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 RX producidas por ruido o por mezcla de firmas espectrales, al eliminar aquellas detecciones que no correspondan con los materiales de interés.

En cuanto a líneas futuras de este trabajo, se considera que deben mejorarse los algoritmos utilizados de detección y clasificación de anomalías, utilizando por ejemplo técnicas basadas en *machine learning*, especialmente para mejorar su robustez en imágenes reales que presentan habitualmente píxeles con mezcla de firmas espectrales. Para ello, es necesario utilizar métricas cuantitativas para comparar los resultados obtenidos con distintos algoritmos aplicados sobre conjuntos de datos de prueba para la detección y clasificación de anomalías de los que se conozca su *ground truth*. Además, un análisis más completo de los algoritmos permitiría establecer estimaciones sobre las capacidades en escenarios reales de los sistemas hiperespectrales como su alcance máximo o el tamaño mínimo detectable para un determinado material o blanco de interés sobre un determinado fondo. Para ello, podrían utilizarse imágenes hiperespectrales capturadas con un sensor comercial embarcado en un dron, que permitirían además evaluar los efectos de la estabilidad de la plataforma en la calidad de la imagen hiperespectral. Finalmente, se requiere llevar a cabo un estudio y optimización de la carga computacional de los algoritmos implementados, ya que uno de los principales inconvenientes del uso de sensores hiperespectrales es su limitación para operar en tiempo real.

Bibliografía

- [1] D. Manolakis, David M. y G.A. Shaw. “Hyperspectral image processing for automatic target detection applications”. En: *Lincoln Laboratory Journal* 14 (2003).
- [2] Y. Adeel K. Lhurrám K. Muhammad Jaleed K. Hamid Saeed y A. Asad. “Modern Trends in Hyperspectral Image Analysis: A Review”. En: *IEEE Access* 6 (2018).
- [3] *Tecnología e Innovación, Defensa*. URL: <http://www.tecnologiaeinnovacion.defensa.gob.es/en-us/Estrategia/HojasDeRuta/Pages/ISTAR.aspx>.
- [4] Cátedra Isdefe-upm. “Sistemas ISTAR – Análisis de sensores ópticos embarcados .Estado del Arte de las Tecnologías”. En: (2018).
- [5] L. Pádua J. Bessa E. Peres-R. Morais T. Adão J. Hruška y J. Sousa. “Hyperspectral imaging: A review on UAV-based sensors, data processing and applications for agriculture and forestry”. En: *Remote Sensing* 9 (2017).
- [6] *Xudong Kang’s Homepage - Home*. URL: <http://xudongkang.weebly.com/>.
- [7] *Sentinel Data*. URL: <https://scihub.copernicus.eu/dhus/#/home>.
- [8] C.F Romero. “La I + D en Defensa y Seguridad ”. En: (2013).
- [9] F. A. Rojas-Morales S. F. Castillo-Castelblanco H. Arguello-Fuentes A. Camacho-Velasco C. A. Vargas-García. “Aplicaciones y retos del sensado remoto hiperespectral en la geología colombiana ”. En: *Revista Facultad de Ingeniería (Fac. Ing.)* 24 (2015).
- [10] E. SánchezBernabé. “Procesado de imágenes hiperespectrales”. En: (2016). URL: <http://oa.upm.es/44860/>.
- [11] G. Wedell. “Employment issues in Europe in the 1980s. Librería USGS”. En: (1980).
- [12] C. Chang. *Real-Time Progressive Hyperspectral Image Processing*. 2016.
- [13] A. Cisz. “Performance comparison of hyperspectral target detection algorithms”. En: (2006).
- [14] A. Pose. “Adquisición, procesamiento y análisis de imágenes hiperespectrales: de la microscopía de fluorescencia a la industria satelital”. En: (2017).
- [15] M. M Crawford. X. Jia B.C Kuo. “Feature mining for hyperspectral image classification”. En: *Proceedings of the IEEE* 101 (2013).
- [16] M.C. Mouchot M. Lennon G. Mercier, L. y Hubert-Moy. “Independent component analysis as a tool for the dimensionality reduction and the representation of hyperspectral images”. En: *IGARSS* 2 (2002).
- [17] X. Weixin G. Lixin y P. Jihong. “Segmented minimum noise fraction transformation for efficient feature extraction of hyperspectral images”. En: *Pattern Recognition* 48 (2015). URL: <http://dx.doi.org/10.1016/j.patcog.2015.04.013>.
- [18] D. Manolakis y G. Shaw. “Detection algorithms for hyperspectral imaging applications”. En: *IEEE Signal Processing Magazine* 19 (2002).

- [19] M. Pieper T. Cooley D. Manolakis E. Truslow y M.Brueggeman. “Detection algorithms in hyperspectral imaging systems: An overview of practical algorithms”. En: *IEEE Signal Processing Magazine* 31 (2014).
- [20] G. Camps-Valls P. Scheunders N. M. Nasrabadi J.Bioucas-Dias A. Plaza y J. Chanussot. “Hyperspectral remote sensing data analysis and future challenges”. En: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 5 (2013).
- [21] A. Villalobos Pinzón. “Procesamiento digital de imágenes hiperespectrales”. En: (2017).
- [22] R. Scafutto y C. Filho. “Detection of methane plumes using airborne midwave infrared (3-5 μm) hyperspectral data”. En: *Remote Sensing* 10 (2018).
- [23] J. C Valdiviezo Navarro. “Segmentación de Imágenes Hiperespectrales usando Memorias Asociativas Morfológicas ”. En: (2007).
- [24] A. Plaza. “Procesamiento paralelo de imágenes hiperespectrales”. En: (2017).
- [25] D. Wu y D. Wen Sun. “Advanced applications of hyperspectral imaging technology for food quality and safety analysis and assessment: A review - Part I: Fundamentals”. En: *Innovative Food Science and Emerging Technologies* 19 (2013).
- [26] H. Grahn P.Geladi y J. Burger. “Hyperspectral Imaging : Background and Equipment”. En: *Techniques and Applications of Hyperspectral Image Analysis* (2007).
- [27] C. Gonzalez Calvo. “Procesamiento a bordo de imágenes hiperespectrales de la superficie terrestre mediante hardware reconfigurable”. En: (2011).
- [28] M. Moore. *Hyperspectral Remote sensing*. 2016.
- [29] *Imagen f180627t01p00r05rdn e sc01 ort img*. URL: https://aviris.jpl.nasa.gov/alt_locator/.
- [30] *Introduction to K-means Clustering*. URL: <https://www.datascience.com/blog/k-means-clustering>.
- [31] *The 5 Clustering Algorithms Data Scientists Need to Know*. URL: <https://towardsdatascience.com/the-5-clustering-algorithms-data-scientists-need-to-know-a36d136ef68>.
- [32] M. Diani S. Matteoli y G. Corsini. “A tutorial overview of anomaly detection in hyperspectral images”. En: *IEEE Aerospace and Electronic Systems Magazine* 25 (2010).
- [33] L. Hoff E. Winter-A. Schaum D.Stein S.Beaven y A. Stocker. “Anomaly detection from hyperspectral imagery”. En: *IEEE Signal Processing Magazine* 19 (2002).
- [34] N. Dobigeon M.Parente Q. Du P. Gader J. Bioucas-Dias A. Plaza y J.Chanussot. “Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression-based approaches”. En: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 5.2 (2012).
- [35] *ToolBox usada para sparse regression*. URL: <http://www.lx.it.pt/~bioucas/publications.html>.
- [36] *Sentinel-2 - Missions - Sentinel Online*. URL: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2>.
- [37] C. Lora A. José y J. Sánchez. “Diferente Resolución Espectral En La Exploración Minera”. En: (2016).
- [38] *Geo-soluciones Aster*. URL: <https://www.geosoluciones.cl/aster/>.
- [39] *GeoSpatial - Satélite WorldView-3*. URL: <http://www.geospatial.com.co/imagenes-de-satelite/worldview-3.html>.

-
- [40] *AVIRIS - Airborne Visible / Infrared Imaging Spectrometer*. URL: <https://aviris.jpl.nasa.gov/>.
- [41] G. Thf. “Summaries of the Fifth Annual JPL Airbone Earth Science Workshop”. En: (1995).
- [42] *ROSIS — Center for Remote Sensing (CRS)*. URL: https://crs.hi.is/?page{_}id=877.
- [43] *Hyperspectral Imaging Cameras — Hyperspectral Imaging Systems — Hyperspectral Machine Vision*. URL: <https://resonon.com/hyperspectral-cameras>.

Apéndice A

Impactos debidos a este proyecto

A.1. Contexto general

Este trabajo de fin de grado se ha desarrollado dentro de la Cátedra Isdefe-UPM y su objetivo principal es generar una cadena de procesamiento para conseguir detectar anomalías en imágenes hiperespectrales obtenidas de sensores embarcados en satélites, aviones o drones. Esta tecnología sigue avanzando hoy en día y todavía no ha alcanzado su máximo potencial, ya que no hay gran cantidad de sensores hiperespectrales puestos en marcha, de momento se siguen usando los sensores multispectrales en muchas aplicaciones. Dentro del ámbito donde se desarrolla este trabajo, Defensa y Seguridad, se requiere una constante actualización para poder prevenir ataques, tener las herramientas necesarias para combatirlos y hacer que el entorno en el que vivimos sea más seguro. Este tipo de sensores pueden ser utilizados para luchar contra actividades ilegales camufladas, como el narcotráfico.

En el trabajo solamente se desarrollan algoritmos en MATLAB pero la tecnología necesaria para adquirir los datos procesados es bastante costosa. Es necesario seguir investigando mucho más para conseguir incrementar su uso en aplicaciones militares, como identificación de objetivos en campo de batalla, ya que actualmente el procesamiento de estas imágenes tarda debido a la gran carga computacional que tienen, por lo que su uso en aplicaciones en tiempo real todavía está en estudio.

Actualmente estas imágenes se utilizan para analizar multitud de parámetros, como en la agricultura para medir los índices de clorofila y agua, analizar parámetros físicos del agua y otras aplicaciones mencionadas en el Anexo C. Por lo tanto estas imágenes podrían ayudar también a mejorar el rendimiento de los cultivos aprovechando mejor la tierra y contribuyendo al medio ambiente. También se están desarrollando nuevas aplicaciones con estas imágenes en el ámbito de la sanidad, calidad de alimentos, arte... Por otro lado es una tecnología con un 17,5% de crecimiento anual ya que nos encontramos en una etapa digital, donde se busca poder realizar todo de forma telemática.

A.2. Descripción de los impactos posibles

En el contexto explicado, se ha visto que el trabajo realizado puede resultar beneficioso para el medio ambiente, pero las plataformas usadas y los sensores que se han de producir. La

construcción y puesta en marcha de las plataformas ISTAR donde van embarcados los sensores hiperspectrales, pueden generar un impacto ambiental. Por ejemplo, en cuanto a los satélites cuando estos dejan de operar, unos vuelven a entrar en la atmósfera y otros siguen en órbita abandonados. Esta situación tiene un alto riesgo de generar fragmentos de basura espacial si las baterías o combustible que quedan explotan. Por esta razón agencias como la ESA ya han puesto en marcha medidas para evitar esto y mantener limpio el espacio.

En cuanto al impacto económico generado por el proyecto, puede suponer una reducción de costes en muchas de las aplicaciones explicadas anteriormente. Por ejemplo en el ámbito de agricultura, si con estas imágenes se pueden prevenir plagas mediante el estudio continuo o la mejora de la eficiencia en los cultivos, se ahorrará en fertilizantes, insecticidas... Por otro lado una de las aplicaciones en sanidad que se están desarrollando era la detección de tumores mediante estas imágenes lo que puede conllevar a una reducción de pruebas del paciente y por lo tanto un menor coste. Por último en el ámbito de defensa y seguridad, puede ayudar a reducir costes en vigilancia, ya que un avión/dron y un sensor hiperspectral se pueden vigilar y analizar territorios, consiguiendo también reducir el peligro de los militares que ejercen estas funciones.

En cuanto al impacto ético y social, se puede ver que contribuye al desarrollo de la sociedad, ayudando a realizar tareas con mayor facilidad y también a vivir en un entorno más seguro pudiendo encontrar actividades ilícitas mediante el análisis de estas imágenes. Por otro lado, a la hora de tratar este tipo de imágenes hay que estar seguros de que se cumple con la ley de protección de datos, cumpliendo con una serie de aspectos respecto a la privacidad y los derechos.

A.3. Análisis de impactos más relevantes en el proyecto

En cuanto a los impactos que se han mencionado en la anterior sección, el más influyente será en el ámbito social, ya que gracias al procesamiento de este tipo de imágenes, se facilitará la detección y seguimiento de actividades ilícitas que podrían suponer un peligro. Con esto se disminuirá el peligro que pueden sufrir los agentes a la hora de investigar ciertas zonas.

A.4. Reflexión final

Actualmente el uso de este tipo de sensores no está al 100%, pero pueden suponer grandes mejoras para el futuro. Sobre todo por la seguridad que podríamos adquirir monitorizando con estas imágenes y reduciendo costes en ámbitos públicos. En este trabajo solo se han desarrollado los algoritmos necesarios para el procesamiento de estas imágenes, pero de cara a un proyecto completo este tendría impactos ambientales y económicos buenos y malos. A pesar de esto, debido a su alto coste esta tecnología tardará en implantarse en aplicaciones del día a día.

Apéndice B

Presupuesto económico

Como se ha comentado en el contexto para analizar los impactos, en este proyecto hemos desarrollado una serie de algoritmos para el procesamiento de imágenes hiperespectrales, haciendo uso de Matlab como herramienta software. Por esa razón aquí no se tendrán en cuenta los costes asociados a las plataformas y sensores de los cuales se han adquirido los datos para procesar.

Para realizar este proyecto el tiempo necesario corresponde desde el comienzo de la beca en la Cátedra de ISDEFE (15/09/2018) hasta el inicio de mayo, descontando las semanas de vacaciones y semanas de exámenes se ha realizado en un total de 460 horas aproximadamente. En cuanto a la distribución de las horas dedicadas a cada etapa del proyecto se puede ver la segmentación en la Tabla B.1.

Etapas	Horas
Estudio de las tecnologías hiperespectrales	110
Estudio de los algoritmos posibles	120
Programación de firmas sintéticas para pruebas	50
Programación de los algoritmos para el procesado	90
Simulación y conclusiones firmas sintéticas	40
Simulación y conclusiones datasets	25
Simulación y conclusiones Sentinel	25
Total	460

Cuadro B.1: Segmentación de las horas dedicadas al trabajo

El sueldo bruto medio de un Ingeniero de Telecomunicación (graduado) en España es de 24.729 €, realizando 1.691 horas anuales nos da 14,62 €/hora. Por lo tanto el sueldo por la realización de este proyecto sería $14,62 \text{ (€/hora)} \times 480 \text{ (horas)} = 7017,6 \text{ €}$. También debemos tener en cuenta los costes asociados a la seguridad social del trabajador, siendo estos del 30 % del sueldo aproximadamente, es decir, suponen 2105,28 €.

Por otro lado el ordenador usado para este trabajo tuvo un coste de aproximadamente 1400 € que no se tendrán en cuenta ya que es un ordenador personal. Sin embargo si debemos contabilizar la amortización de este equipo como un 20 % anual, es decir, unos 280 €. El último coste directo que debemos tener en cuenta es la licencia de MATLAB, la cual asciende a 800

€/anuales.

Lo anterior eran los costes directos, en cuanto a los indirectos como la luz, el agua, internet que se estiman en un 25 % del sueldo, es decir, 1754,4 €. Por último tenemos otro coste indirecto en este trabajo referido a la matriculación del TFG, son 12 créditos y a 24,55 € el crédito, obtenemos un total de 294,66 €, más las tasas de secretaría y el seguro escolar que ascienden a 7,23 €.

Todo esto se detalla en la Tabla B.

Concepto	Coste (€)
Costes Directos	
Recursos humanos	
Salario	7017,6 €
Seguridad Social	2105,28 €
Otros	
Licencia Matlab	800€
Amortización Ordenador	280 €
<i>Total Costes Directos</i>	<i>10.202,88 e</i>
Costes indirectos	
Matrícula TFG	294,66 €
Tasas y Seguro	7,23 €
Luz, agua, internet..	1.754,4 €
<i>Total Costes Indirectos</i>	<i>2.056,29</i>
Total	12.259,17 €

Cuadro B.2: Presupuesto final trabajo fin de grado

Apéndice C

Aplicaciones de la tecnología hiperespectral

La tecnología hiperespectral ha servido desde que se descubrió para muchas aplicaciones civiles, ambientales y militares. Se ha utilizado en tareas de teledetección que requieren medir parámetros físicos de superficies pequeñas e identificar materiales similares, ya que tienen buenas resoluciones temporales, espectrales y espaciales. Cada vez se utilizan para mayor número de aplicaciones, pero en sus inicios ha sido explotada, sobre todo, en el ámbito de la agricultura, geología y militar. En este anexo se verán algunas de las aplicaciones más modernas de este ámbito.[20],[2]

Calidad y seguridad de los alimentos:

La calidad y seguridad de los alimentos se evalúan mediante el examen de los atributos físicos, químicos y biológicos. Los métodos que se usaban tradicionalmente necesitan de mucho tiempo y son considerados malos para el medio ambiente. En este ámbito se han utilizado métodos basados en machine learning que usan el procesamiento de imágenes en color para ver las características externas de los alimentos. Sin embargo, gracias a la espectroscopia de infrarrojo cercano (NIR) ayudó a capturar información del interior de los alimentos, pero no conseguía examinar materiales heterogéneos. Esta limitación la consiguieron superar las imágenes hiperespectrales gracias a la gran cantidad de información espectral y espacial. El análisis con estas imágenes se ha usado para identificar defectos y detección de contaminaciones en productos alimenticios.

Diagnóstico médico:

Gracias a la imagenología espectral se ha podido dar mayor velocidad y precisión en los resultados clínicos. El análisis de imágenes hiperespectrales se está utilizando en este ámbito debido a que tienen una gran capacidad de proporcionar imágenes en tiempo real de biomarcadores o tejidos. También se ha demostrado que son útiles para la detección de tumores, viendo si un tejido es maligno o benigno a través de las diferencias en sus firmas espectrales. Aparte del diagnóstico, también se utilizan para cirugía guiada por imágenes.

Agricultura de precisión:

Debido al crecimiento de la población mundial es necesario incrementar la producción mundial de cultivos. Se ha llegado a la conclusión de que la mejor forma es aumentar el rendimiento sin necesidad de utilizar más tierra, garantizando la seguridad alimentaria. Tradicionalmente, monitorizar los cultivos, detectar enfermedades, nutrientes y ataques de insectos se realizaba examinando manualmente el suelo. La pega de estos métodos es que los síntomas visuales suelen aparecer al final de la enfermedad. Gracias a la tecnología hiperespectral se ha conseguido evaluar, analizando las características del suelo y la vegetación de una manera más rápida y rentable. El estrés de la sequía es un factor que afecta al rendimiento de los cultivos y gracias a los sensores se pueden detectar cambios en los pigmentos de forma temprana. También se utilizó para encontrar contaminación en los suelos de cultivo ya que se puede observar los niveles de clorofila indicándonos síntomas de estrés por tóxicos.

Recursos hídricos:

Se debe conseguir un manejo eficiente de los recursos hídricos, analizar y monitorizar la calidad del agua. Gracias a la tecnología hiperespectral se pueden hacer estimaciones más precisas de los parámetros necesarios para medir los recursos hídricos analizando variaciones espectrales, espaciales y temporales del agua. Hay estudios geológicos de los Estados Unidos que ayudan a realizar sistemas de alerta temprana consiguiendo prevenir descargas de ríos o inundaciones. También nos proporcionan información eficaz y fiable sobre parámetros de calidad del agua por sus características bioquímicas. Nos permite medir la clorofila, turbidez demanda de oxígeno... Se ha considerado que estos sistemas pueden ser muy importantes a la hora de reconstruir y restaurar los ecosistemas.

Examen de documentos forenses:

Normalmente se usan métodos químicos para estudiar los documentos históricos importantes y verificar la validez de estos. Como todos los métodos de los que hemos hablado tradicionales, requerían mucho tiempo y por cambios de temperatura, documentos importantes podrían ser destruidos. Las imágenes hiperespectrales de estos documentos se basan en que cada tinta tiene su firma espectral única. Además tienen la ventaja de que este proceso no destruye los documentos y es insensible a cambios de temperatura. Esta técnica también es utilizada en la detección de falsificaciones utilizando redes neuronales (CNN) o algoritmos de clustering (k-means).

Autenticación de obras de arte:

Como en el anterior punto, los métodos usados hasta ahora ponían en peligro la integridad de las obras. La tecnología hiperespectral reduce el número de pruebas necesarias y nos da una mayor información. Se han propuesto varios métodos que emplean análisis de pigmentos y clasificación para la conservación de obras de arte. Estos métodos permiten distinguir las regiones restauradas de las importantes.

Defensa y seguridad:

Se utiliza sobre todo para detectar y reconocer objetivos camuflados en aplicaciones militares. Se puede detectar en bosques, montañas o desiertos, objetivos como vehículos militares incluso si están camuflados. En este caso se suelen usar métodos de detección de anomalías donde diferencian sin objetivo previo. Gracias a esta tecnología también han sido probados algoritmos y redes neuronales artificiales (RNA) en la detección de minas terrestres ocultas, midiendo la temperatura del suelo en la zona observada, llegando a que la temperatura del suelo perturbado era más alta que la del suelo no perturbado. Concluyeron que esta tecnología tiene un alto potencial en la detección y reconocimiento de objetos semiocultos, minas terrestres ocultas y camufladas si se tiene un mínimo conocimiento previo de su existencia, pero esto se complica cuando las minas estaban completamente ocultas. Otro ámbito en el que se usa es en la detección de artefactos explosivos improvisados.

Como se ha podido ver las imágenes hiperespectrales tienen un papel muy importante en un gran número de aplicaciones basadas. Debido al gran número de ámbitos en los que se desarrolla, cada vez se investigan muchas más herramientas y algoritmos matemáticos, como la fusión de datos, desmezcla, clasificación, detección de anomalías... para conseguir una computación de datos más eficaz.[27]

Apéndice D

Plataformas en las que van embarcadas los sensores

Hay distintos tipos de plataformas ISTAR según la función a la que se van a dedicar: plataformas terrestres, navales, espaciales y aéreas. En nuestro caso nos centraremos en las dos últimas, que son las más utilizadas para sensores hiperspectrales.[4]

D.0.1. Plataformas espaciales

Estas plataformas son las más usadas en tareas de observación de diferentes zonas terrestres y son capaces de registrar imágenes de forma simultánea en varias bandas espectrales. Estos siguen un movimiento continuo, según su órbita, de la que dependerá su resolución temporal. En estas plataformas no conseguiremos una gran resolución espacial, del orden de decenas de metros, pudiendo contener diferentes tipos de materiales.

Satélite Sentinel:

Ha sido desarrollado por la ESA dentro del Programa Copérnico. Dentro de este satélite hay diferentes misiones dedicada a funciones radar o a medición de imágenes espectrales para vigilancia terrestre, atmosférica u oceánica. La misión que nos interesa es la de Sentinel-2 formado por una constelación de dos satélites multispectrales en órbita polar situados en fases de 180° entre sí. El objetivo de esta misión es observar la variabilidad de las condiciones de la superficie terrestre así como cambios en la vegetación dentro de la temporada de crecimiento. Su tiempo de revisión es de 10 días en el ecuador con un satélite y 5 días con 2 satélites aproximadamente. En su interior el haz de luz entrante se divide en dos planos separados, uno para bandas visibles y casi infrarrojas (VNIR) y otro para bandas de infrarrojo de onda corta (SWIR).[36]

Sensor Hyperion a bordo del satélite EO-1:

Mide más de 220 bandas y cubre el rango espectral de 400-2500 nm con una anchura de bandas de 10nm. De este sensor han sido sacados muchos de los datos utilizados en diversos artículos para el desarrollo de algoritmos. También se ha utilizado la información de este sensor para formar parte la librería de firmas espectrales USGS.[37]

Landsat 8:

Su tiempo de revisión en este caso es de aproximadamente 16 días. Este satélite lleva a bordo dos sensores multiespectrales: sensor OLI (operational land imager) que capta el espectro visible, infrarrojo cercano (NIR) e infrarrojo de onda corta (SWIR); y sensor TIRS (Thermal infrared sensor) que mide la temperatura de la superficie terrestre. Como casi todos los sensores embarcados en satélites consiguen una baja resolución espacial, de unos 30 m aproximadamente. Este sensor también ha sido utilizado para completar la librería USGS.[37]

Sensor HRVIR a bordo del satélite SPOT-5:

se trata de un satélite de teledetección civil para la observación del suelo terrestre. La innovación de este respecto a los demás es un modo que permite crear una imagen de unos 2.5 m de resolución a partir de dos imágenes de 5 metros. Con esto se consigue que tenga una resolución espacial de 10 m trabajando dentro de la franja visible e infrarrojo.[37]

Satélite ASTER:

Se lanzó en 2009, recoge imágenes del espectro visible y también las regiones infrarrojas, con resoluciones espaciales de 15 a 90 metros. Indicaron que este satélite será útil para usuarios e investigadores que quieran información sobre la elevación del terreno.[38]

Satélite WorldView3:

Se lanzó en 2014 y es considerado como uno de los satélites con mejor resolución actualmente. Capta 8 bandas multiespectrales y fue diseñado para apoyo humanitario y aplicaciones de agricultura y geológicas.[39]

D.0.2. Plataformas aéreas:

Dentro de este apartado podemos encontrar dos tipos de plataformas aéreas. Las aeronaves que consiguen mayor resolución espacial que los satélites pero tienen peor estabilidad ya que trabajan en la zona más turbulenta de la atmósfera. Por otro lado las aeronaves pilotadas remotamente, UAV, cuya ventaja es la ausencia de un piloto, tienen las mismas desventajas que las aeronaves tripuladas añadiendo la problemática de la cara y procesamiento de datos en una plataforma de sus dimensiones. A continuación veremos los sensores embarcados en aeronaves más utilizados en estudios para la mejora de algoritmos de procesamiento y algunos de los implantados en UAV

Sensor AVIRIS:

Es un sensor óptico usado para la teledetección de la Tierra, capta 224 bandas desde los 400 nm hasta los 2500 nm. Este sensor ha sido volado en cuatro plataformas de aviones: el jet ER.2 de la Nasa, el turbopropulsor de Twin Otter International, el WB-57 de la Nasa y el Scaled Composites Proteus. El objetivo principal de este sensor es identificar, medir y monitorear las características de la superficie y atmósfera terrestre.[40]

Sensor HYDICE:

Se trata de un sensor hiperespectral que capta 210 bandas en el rango de 400-2500 nm y lleva funcionando desde 1994.[41]

Sensor Rosis:

Se trata de un sensor que lleva volando desde 1992, cubre desde los 430 nm a los 860nm adquiriendo un total de 115 bandas con 4nm de ancho de banda cada una. El objetivo principal del proyecto es detectar estructuras espectrales finas, sobre todo en aguas costeras.[42]

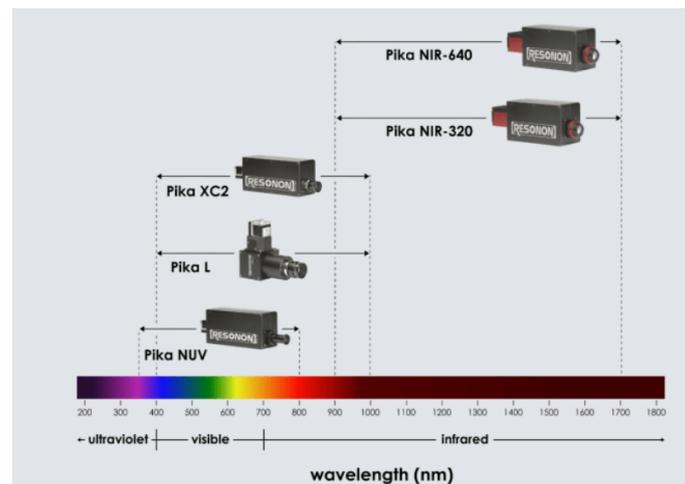


Figura D.1: Cámaras Hiperespectrales ofrecidas por la empresa Resonon .[43]

Por otro lado hay empresas como Resonon que fabrican cámaras hiperespectrales muy pequeñas para incorporarlas en UAV. Las cámaras desarrolladas para sistemas de sentido remoto por esta empresa consiguen cubrir el rango de 400 a 1700 nm y vienen equipadas con el hardware y software necesario para adquirir y analizar los datos medidos. Tienen una colección de cámaras hiperespectrales llamadas Pika NIR-320, Pika L... según el rango del espectro y las características que queramos como vemos en la Figura D.1.[43] Otra empresa que fabrica estos sistemas es Cubert, donde podemos ver que optan por sensores de disparo único por la eficiencia que tienen al capturar todo el conjunto de datos tridimensionales con una sola lectura del sensor.