

# **Detección de anomalías en imágenes hiperespectrales**

**Estado del Arte de las  
Tecnologías**

**Cátedra Isdefe-UPM**

---

**Septiembre 2018 – Junio 2019**

**Madrid, junio de 2019**

# Índice general

<b>1. Introducción</b>	<b>1</b>
1.1. Ventajas e inconvenientes tecnología hiperespectral . . . . .	2
1.2. Proceso de adquisición y procesado de los datos . . . . .	4
<b>2. Fundamentos de la tecnología hiperespectral</b>	<b>6</b>
<b>3. Aplicaciones de la tecnología hiperespectral</b>	<b>11</b>
<b>4. Plataformas en las que van embarcadas los sensores</b>	<b>14</b>
4.1. Plataformas espaciales . . . . .	14
4.2. Plataformas aéreas: . . . . .	15
<b>5. Procesamiento de datos hiperespectrales</b>	<b>17</b>
5.1. Reducción de dimensionalidad basada en PCA . . . . .	17
5.2. Segmentación de imágenes hiperespectrales . . . . .	19
5.3. Algoritmos para la detección de anomalías . . . . .	23
5.4. Algoritmos para la clasificación de anomalías . . . . .	24
<b>Bibliografía</b>	<b>33</b>

# Índice de figuras

1.1. Firmas espectrales de cuatro materiales diferentes (lona verde, lona azul, hierba y asfalto) [9], 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 procesamiento de imágenes hiperespectrales. Este trabajo se centra en el procesamiento 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 [21]. . . . .	7
2.2. Proceso de adquisición de imágenes hiperespectrales [22]. 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. . . . .	7
2.3. Modos de adquisición de los sensores hiperespectrales [5]. . . . .	8
2.4. Factores que determinan la resolución espacial de un sensor hiperespectral [25]. . . . .	9
2.5. Comparación de la resolución espectral en sensores hiperespectrales y multiespectrales [26]. . . . .	10
4.1. Cámaras Hiperespectrales ofrecidas por la empresa Resonon [34] . . . . .	16
5.1. Diagrama de las etapas de procesamiento que se seguirán en este trabajo. . . . .	17
5.2. Ejemplo de aplicación de PCA sobre una imagen hiperespectral capturada por el sensor AVIRIS. . . . .	19
5.3. Algoritmo <i>K-means</i> aplicado sobre una imagen hiperespectral para $k = 3$ y $k = 6$ (cada color corresponde a un clúster). . . . .	21
5.4. 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.). . . . .	22

---

5.5. Algoritmo <i>Mean-shift</i> aplicado sobre una imagen hiperespectral (cada color corresponde a un clúster). . . . .	22
5.6. Ventana de referencia para estimar la media y matriz de covarianza muestrales en una zona localizada alrededor de la celda bajo test. . . . .	24
5.7. 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 [18]. . . . .	25
5.8. Conjunto de datos encerrado en un volumen C cuyos vértices son los <i>endmembers</i> [18]. . . . .	26
5.9. Volúmenes de tres conjuntos con datos diferentes[18]. . . . .	28
5.10. Red profunda basada en auto-codificadores apilados [42]. . . . .	29
5.11. Máquina de Boltzman (RBM) para la formación de DBNs[42]. . . . .	29
5.12. Arquitectura de una red convolucional típica[42]. . . . .	30
5.13. Esquema general de GAN [42]. . . . .	31
5.14. Clasificador para imágenes hiperespectrales basado en GAN [42]. . . . .	32

# Capítulo 1

## Introducción

Actualmente hay una necesidad 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].

## 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],[6],[7],[8].

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  $\mu\text{m}$ ) debido a su diferente color, pero en las zonas NIR (*Near-infrared*, 0.7 - 1.4  $\mu\text{m}$ ) e SWIR (*Short-wavelength infrared*, 1.4 - 3  $\mu\text{m}$ ) 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  $\mu\text{m}$ , 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  $\mu\text{m}$  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.

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 [10].

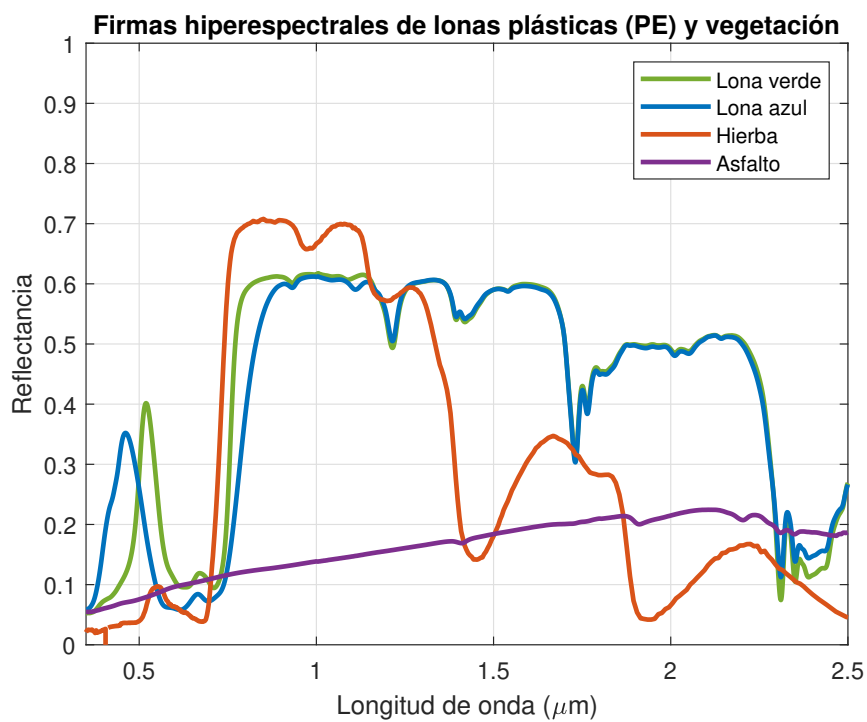


Figura 1.1: Firmas espectrales de cuatro materiales diferentes (lona verde, lona azul, hierba y asfalto) [9], que demuestran la capacidad potencial de los sensores hiperespectrales de clasificar los materiales en base a las diferentes curvas de reflectancia medidas para cada píxel de la imagen, a pesar de que presenten respuestas similares en la zona visible del espectro.

## 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.

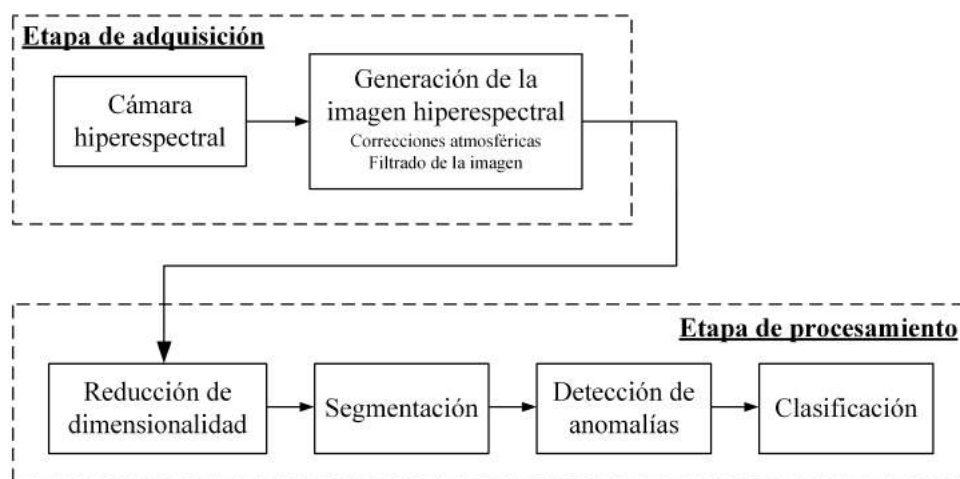


Figura 1.2: Esquema del proceso de adquisición y procesado de imágenes hiperespectrales. Este trabajo se centra en el procesado de la imagen hiperespectral, realizando una segmentación de la imagen y la detección y clasificación de las anomalías que pueden indicar el desarrollo de actividades ilícitas.

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 [6],[11],[12]:

- Algoritmos de reducción de dimensionalidad (*Feature selection*) [13]:
  - *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 [14].



- *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 [15].
- 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 [16, 17]. 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. Por otro lado se estudiarán técnicas de *Deep Learning* analizando diferentes modelos de las redes neuronales capaces de realizar este tipo de clasificación.

## Capítulo 2

# 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, 18, 19]:

- 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  $\mu\text{m}$ ) y las zonas NIR (0.7 - 1.4  $\mu\text{m}$ ) y SWIR (1.4 - 3  $\mu\text{m}$ ), debido a que en ellas el espectro es predominantemente reflectivo, facilitando las operaciones de compensación atmosférica y la extracción de información para la clasificación de los materiales [20]. En cambio, como se representa en la Figura 2.1, en las zonas MWIR (*Medium-wavelength infrared*, 3 - 5  $\mu\text{m}$ ) y LWIR (*Long-wavelength infrared*, 5 - 15  $\mu\text{m}$ ) 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

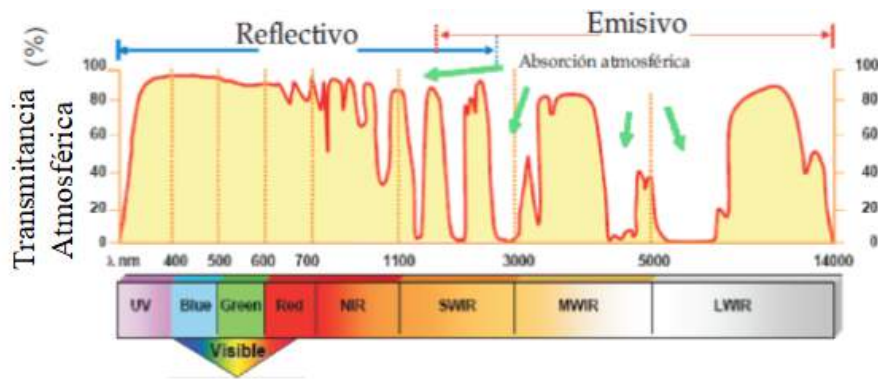


Figura 2.1: Espectro electromagnético y transmitancia atmosférica. En las bandas UV, visibles, NIR y SWIR, los espectros son predominantemente reflectivos, mientras que en las bandas MWIR y LWIR predomina la componente de emisividad [21].

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).




Figura 2.2: Proceso de adquisición de imágenes hiperespectrales [22]. 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.

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*) [12, 23]. 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, 23, 24]:

- 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 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.




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

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 [8].
- 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) [8].
- 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.




Figura 2.4: Factores que determinan la resolución espacial de un sensor hiperespectral [25].

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,

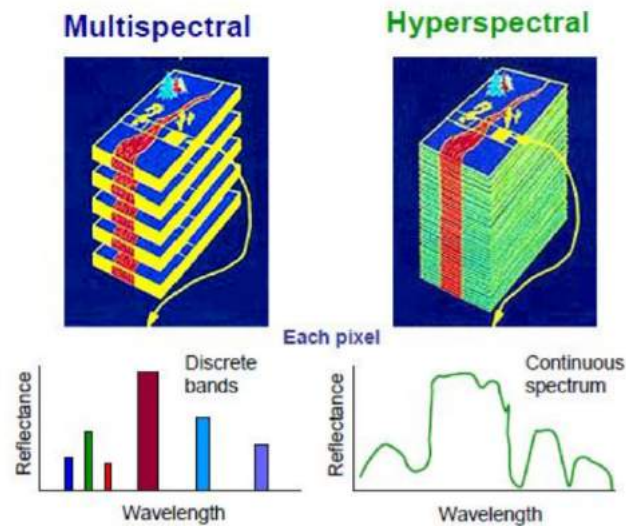


Figura 2.5: Comparación de la resolución espectral en sensores hiperespectrales y multiespectrales [26].

detalladas en el Anexo 3, 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 4. 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.

## Capítulo 3

# 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.[18],[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.[25]

# Capítulo 4

## 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]

### 4.1. 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 multiespectrales 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).[27]

#### **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.[28]

**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.[28]

**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.[28]

**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.[29]

**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.[30]

## 4.2. 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.[31]

### Sensor HYDICE:

Se trata de un sensor hiperespectral que capta 210 bandas en el rango de 400-2500 nm y lleva funcionando desde 1994.[32]

### 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.[33]




Figura 4.1: Cámaras Hiperespectrales ofrecidas por la empresa Resonon .[34]

Por otro lado hay empresas como Resonon que fabrican cámaras hiperespectrales muy pequeñas para incorporarlas en UAV. Las cámaras desarrolladas para sistemas de sensado 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 4.1.[34] 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.

# Capítulo 5

## Procesamiento de datos hiperespectrales

En base a la cadena de procesamiento propuesta e implementada en MATLAB, representada en la Figura 1.2 en este apartado nos centraremos en las etapas representadas en la Figura 5.1, 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 5.1: Diagrama de las etapas de procesamiento que se seguirán en este trabajo.

### 5.1. 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 [21].

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:

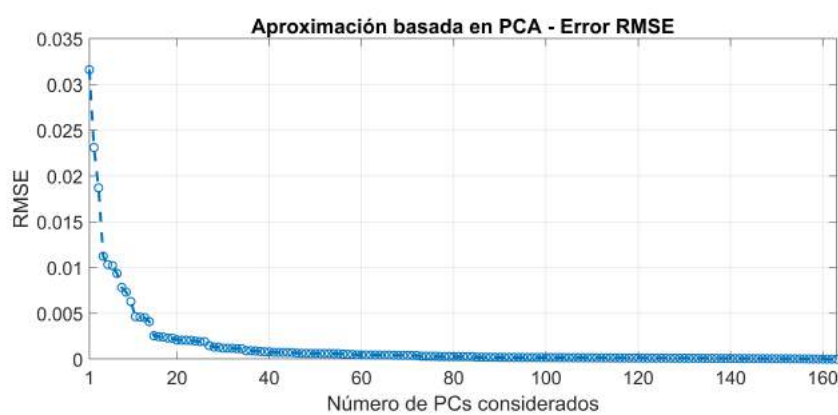
$$A = U_{m \times m} * \Sigma_{m \times n} * V_{n \times n}^T \quad (5.1)$$

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  $\Sigma$  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 5.2 representa los resultados de aplicar el algoritmo PCA a una imagen hiperespectral tomada por el sensor AVIRIS [35]. 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 5.2: Ejemplo de aplicación de PCA sobre una imagen hiperspectral capturada por el sensor AVIRIS.

## 5.2. Segmentación de imágenes hiperspectrales

La segmentación de imágenes permite dividir una imagen en zonas con características similares. En la cadena de procesado 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 hiperspectrales, y es el que emplearemos en la cadena de procesado 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* [36, 37].

### *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:

$$\arg \min_{\mathbf{S}} \sum_{i=1}^k \sum_{\mathbf{x} \in S_i} \|\mathbf{x} - \boldsymbol{\mu}_i\|^2 \quad (5.2)$$

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:

$$\arg \min_i \|\mathbf{x} - \boldsymbol{\mu}_i\| \quad (5.3)$$

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

$$\boldsymbol{\mu}_i = \frac{1}{|S_i|} \sum_{\mathbf{x} \in S_i} \mathbf{x} \quad (5.4)$$

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

La Figura 5.3 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 5.2.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.



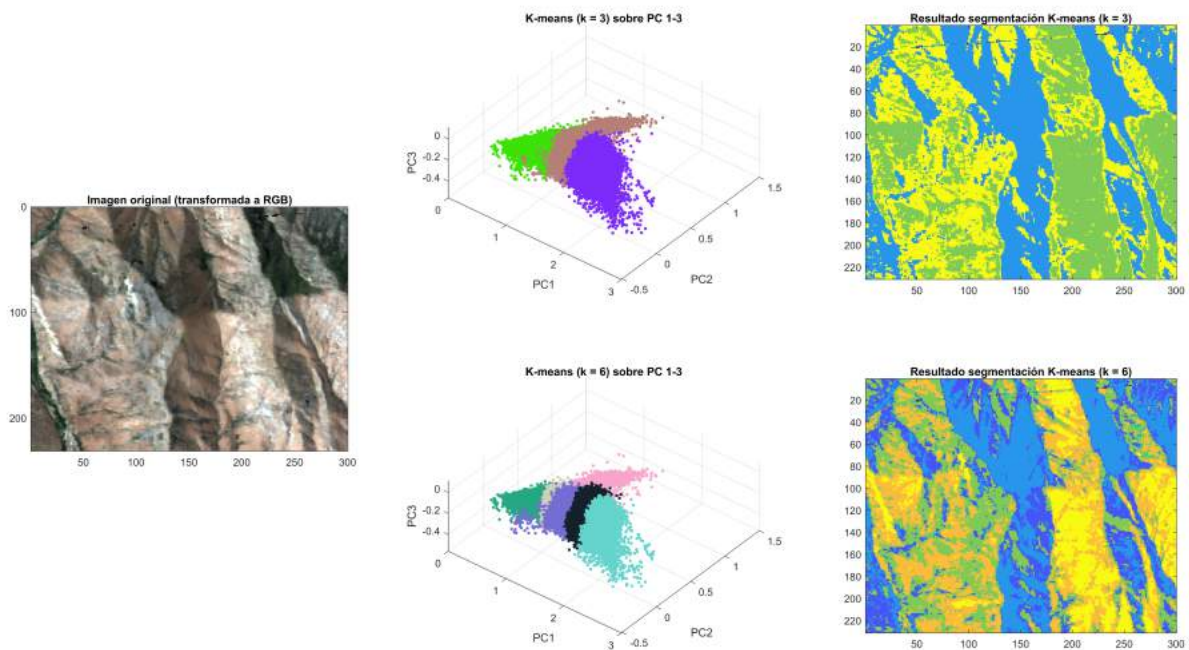


Figura 5.3: Algoritmo *K-means* aplicado sobre una imagen hiperespectral para  $k = 3$  y  $k = 6$  (cada color corresponde a un clúster).

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 5.4 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 5.5 muestra los resultados obtenidos al aplicar el algoritmo *Mean-shift* sobre la imagen hiperespectral de la Figura 5.2.a, segmentando la imagen en ocho zonas.

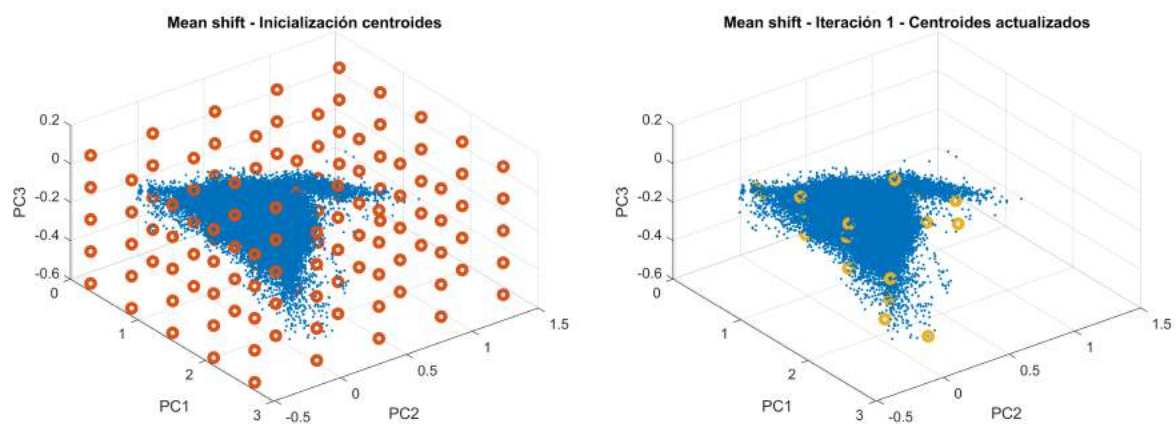


Figura 5.4: Ejemplo de inicialización de los centroides (puntos rojos) en el algoritmo *Mean-shift* (izq.) y de su actualización (puntos amarillos) en la primera iteración hacia zonas con mayor densidad de puntos (dcha.).

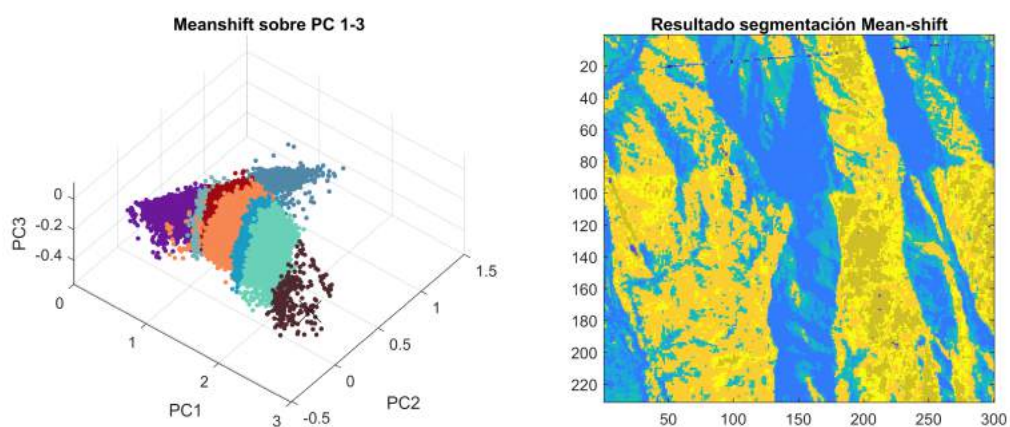


Figura 5.5: Algoritmo *Mean-shift* aplicado sobre una imagen hiperespectral (cada color corresponde a un clúster).

### 5.3. 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) [38, 39] 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  $\theta$  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 (5.5) [39] en la que se compara con un umbral  $\eta$  que establece la probabilidad de falsa alarma.

$$G(x) = \frac{\max_{\theta_1} (p_1(\{x_\ell\}, \theta_1) p_0(\{v_j\}, \theta_1))}{\max_{\theta_0} (p_0(\{x_\ell\}, \theta_0) p_0(\{v_j\}, \theta_0))} \underset{H_0}{\overset{H_1}{\gtrless}} \eta \quad (5.5)$$

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

$$\begin{aligned} H_0 : x &\rightarrow N(\mu, \Gamma_x) \\ H_1 : x &\rightarrow N(s, \Gamma_x) \end{aligned} \quad (5.6)$$

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:

$$RX(x) = (x - \hat{\mu})^T \left( \frac{N}{N+1} \hat{\Gamma}_x + \frac{1}{N+1} (x - \hat{\mu})(x - \hat{\mu})^T \right)^{-1} (x - \hat{\mu}) \underset{H_0}{\overset{H_1}{\gtrless}} \eta \quad (5.7)$$

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 (5.7) 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 5.6. 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.

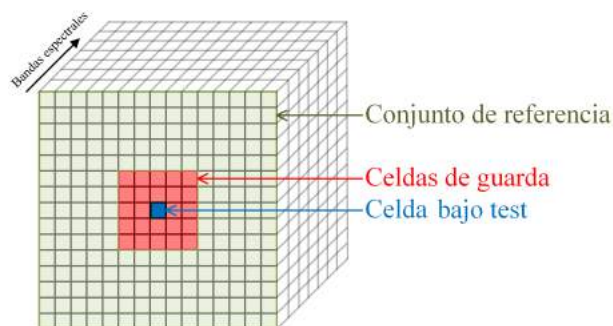


Figura 5.6: Ventana de referencia para estimar la media y matriz de covarianza muestrales en una zona localizada alrededor de la celda bajo test.

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.

## 5.4. Algoritmos para la clasificación de anomalías

### Clasificación mediante Sparse Regression

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.




Figura 5.7: 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 [18].

Existen diferentes técnicas para modelar la mezcla de las firmas espectrales 5.7, entre las que destaca el modelo de mezcla lineal [18], que asume que la curva espectral medida para un 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:

$$\mathbf{x} = \mathbf{M}\alpha + \mathbf{w} \quad (5.8)$$

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* [40] 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  $\alpha$  puede expresarse como un problema de minimización:

$$\min_{\alpha} \|\alpha\|_0 \quad \text{sujeto a} \quad \|\mathbf{A}\alpha - \mathbf{x}\|_2 \leq \delta, \alpha \succeq 0 \quad (5.9)$$

donde  $\|\alpha\|_0$  representa el número de componentes no nulas del vector de abundancias  $\alpha$  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  $\ell_0$ , por la norma  $\ell_1$ , como la aproximación CBPDN (*Constrained basispursuitdenoising*) [40]:

$$\min_{\alpha} \|\alpha\|_1 \quad \text{sujeito a} \quad \|\mathbf{A}\alpha - \mathbf{x}\|_2 \leq \delta, \alpha \succeq 0 \quad (5.10)$$

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

$$\min_{\alpha} \left( \frac{1}{2} \right) \|\mathbf{A}\alpha - \mathbf{x}\|_2 + \lambda \|\alpha\|_1 \quad \text{sujeito a} \quad \alpha \succeq 0 \quad (5.11)$$

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 [41].

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.

### Clasificación geométrica

Teniendo en cuenta el modelo de mezcla lineal y las aproximaciones establecidas en el anterior apartado, se puede clasificar los materiales considerando el conjunto de datos como un volumen denominado  $C$  encerrado por los *endmembers*. En la figura 5.8 se puede observar este volumen, donde los puntos rojos son los *endmembers* (píxeles puros) y los verdes representan los píxeles mezcla (vectores espectrales). Esta clasificación se basa en una interpretación geométrica convexa [18].

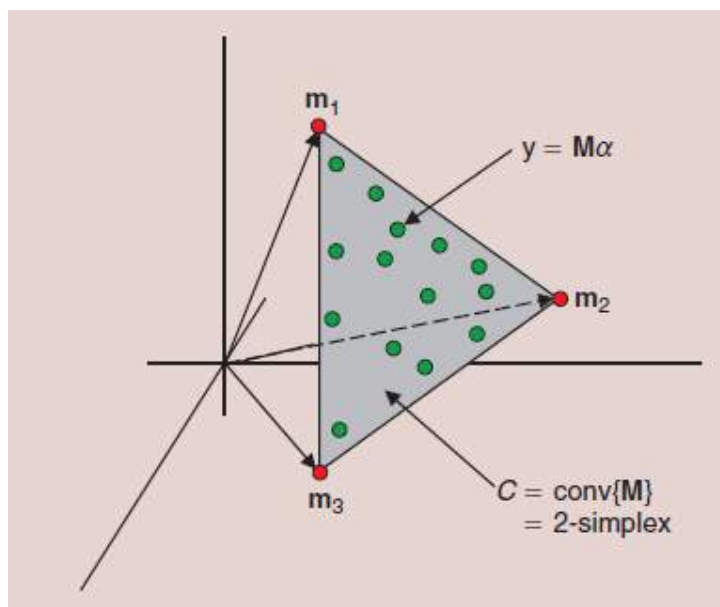


Figura 5.8: Conjunto de datos encerrado en un volumen  $C$  cuyos vértices son los *endmembers*[18].

$$C := \left\{ y = M\alpha : \sum_{j=1}^p \alpha_j, \alpha_j \geq 0, 0 = 1, \dots, p \right\} \quad (5.12)$$

En este problema se deduce a partir de la matriz  $M$  los vértices del volumen  $C$ -simplex, como se observa en la ecuación 5.12, donde  $p$  son el número de *endmembers*. En la figura 5.9, se observan tres volúmenes diferentes. En el primero asume la presencia de al menos un píxel puro por *endmember*. Esta supuesto es un requisito muy importante y no se consigue con facilidad en la mayoría de los conjuntos de datos. En este caso se explotan dos propiedades de las firmas de los *endmembers*.

- Los extremos de la proyección de los vectores espectrales sobre cualquier subespacio se corresponden con los *endmembers*. En este caso se usan algoritmos como el índice de pureza de píxeles (PPI), el análisis de componentes de vértices (VCA), el algoritmo de crecimiento simplex (SGA)...
- El volumen definido por cualquier conjunto de vectores espectrales es máximo cuando estos vectores son los *endmembers*. Aquí se utilizan algoritmos como N-FINDR, análisis de errores iterativos (IEA), maximización de volumen alternante (AVMAX)...

En el segundo y tercer volumen de la figura 5.9 se pueden ver conjuntos de datos sin píxeles puros pero contienen al menos  $p-1$  vectores espectrales en cada cara. En este caso los *endmembers* pueden definirse ajustando un volumen mínimo(MV) simplex a los datos, como se observa en el volumen de la derecha de la imagen. Esto lleva a varios algoritmo de desmezcla con base geométrica, en la ecuación 5.13 se observa la optimización que se formula para estos conjuntos de datos. Para este caso se usa el algoritmo iterativo de los *endmembers* restringidos (ICE) y el algoritmo de la factorización de la matriz transformadora no negativa de volumen mínimo (MVC-NMF).

En el tercer volumen mostrado se ve que el conjunto de datos esta muy mezclado y no hay vectores espectrales cerca de las caras. Para este caso se utilizan marcos estadísticos formulando el problema adoptando el paradigma bayesiano.

$$\min_{M,A} \| \mathbf{Y} - \mathbf{MA} \|_F^2 + \lambda \mathbf{V}(\mathbf{M}) \quad \text{sujeto a: } A \geq 0, \mathbf{1}_p^T A = \mathbf{1}_n \quad (5.13)$$

## Clasificación mediante técnicas de Deep Learning

En los últimos años las técnicas de deep-learning han sido introducidas a la hora de procesar datos de sensado remoto. La clasificación de datos hiperespectrales con este tipo de técnicas resulta más difícil que con otros datos ópticos, a pesar de esto en los últimos años se ha progresado bastante consiguiendo grandes avances en la extracción de características para resolver problemas no lineales. Este tipo de clasificación suele complicarse debido a que para al formación de las redes profundas se requieren un gran número de muestras y en este campo por lo general son muy limitados. Por esta razón en la clasificación de imágenes hiperespectrales hay dos grandes problemas a abordar: la gran variabilidad espacial de las firmas espectrales






Figura 5.9: Volúmenes de tres conjuntos con datos diferentes[18].

y las pocas muestras disponibles para entrenar en comparación a la alta dimensionalidad de los datos. A continuación se detallan varios modelos de clasificación basados en deep learning, correspondientes a los más usados en este campo [42].

### Stacked Autoencoders, SAEs

Los autocodificadores son la parte más importante de estas redes profundas. Están compuestos de una capa visible con  $d$  entradas, una oculta con  $L$  unidades y una capa de reconstrucción de  $d$  unidades. Esto se puede observar en la figura 5.10, donde el entrenamiento de la red tiene dos pasos, primero  $x$  es mapeada en  $h$  en la capa oculta, tras eso después  $h$  es mapeada a  $y$ .

Este modelo aprende de las características de la capa oculta  $h$ , minimizando el error entre la entrada  $x$  y la salida reconstruida  $y$ . Este error se estima usando la distancia euclídea entre  $x$  e  $y$ , se puede expresar como se indica en las ecuaciones 5.14, donde  $w_h$  y  $w_y$  corresponden a los pesos de entrada y salida de la capa oculta, y  $b_h$  y  $b_y$  los sesgos de la capa oculta. SAE se construye apilando varios auto-codificadores

$$h = f(w_h x + b_h) \quad y = f(w_y h + b_y) \quad (5.14)$$

### Deep Belief Networks, DBNs

La máquina de Boltzmann (RBM) restringida es un modelo de formación por capas y es el bloque principal de este tipo de red profunda, DBN. En la figura 5.11 se observa una RBM de dos capas con unidades visibles  $v = 0,1^d$  y con unidades ocultas  $h = 0,1^L$ , donde  $w$  y  $b$  corresponden a los mismos parámetros que en la anterior red explicada (SAE). En este caso los pesos los aprende usando la divergencia y las unidades ocultas están condicionadas independientemente y con esto se puede obtener una muestra imparcial de la distribución posterior cuando se introduce un vector de datos. Igual que en SAE, si apilamos RBM individuales estas forman una DBN y si se añade una etapa con regresión logística se consigue una mejor clasificación.






Figura 5.10: Red profunda basada en auto-codificadores apilados [42].




Figura 5.11: Máquina de Boltzman (RBM) para la formación de DBNs[42].

## Convolutional Neural Networks, CNNs

Este tipo de redes se basan en la estructura del sistema visual usando conexiones locales para extraer características espaciales en 2D. Los parámetros de entrada de esta red pueden reducirse mediante un mecanismo de reparto de peso. En la figura 5.12 se observa una arquitectura de este tipo de red muy típica. Esta se compone de varias capas de convolución y de agrupamiento alternas con un gran número de capas intermedias para conectarlas. En las capas convolucionales los trozos de imágenes con información espacial se entrecruza con un conjunto de núcleos. Tras esto, las capas de agrupamiento reducen el tamaño de los mapas generados en las capas convolucionales para obtener características más generales. Por último estos mapas se transforman en vectores de características a través de varias capas completamente conectadas.

La parte más importante de estas redes con las capas convolucionales, donde en cada una el cubo de entrada es entrelazado con múltiples filtros aprendibles formando los mapas de características mencionados antes. Por otro lado están las capas de agrupamiento que se insertan periódicamente debido a la existencia de información redundante. Gracias a estas se consigue reducir el tamaño espacial de los mapas de características y el número de parámetros de la red. Por último tras esta capa se aplican las capas de conexión para conseguir características más detalladas recolocando la información en vectores de características.




Figura 5.12: Arquitectura de una red convolucional típica[42].

## Recurrent Neural Networks, RNNs

Este tipo de redes pueden reconocer patrones en secuencias de datos y características temporales dinámicas usando un estado oculto que se activa dependiendo de los estados anteriores. El rendimiento de este tipo de redes puede degradarse con datos secuenciales a largo plazo y para abordar este problema (memoria corta) se ha introducido una unidad recurrente (GRU). Este tipo de redes son muy adecuadas para el análisis de características HSI, ya que cada vector de píxel en los datos hiperespectrales puede considerarse como un conjunto de secuencias espectrales ordenadas y continuas en el espacio espectral.

## Generative Adversarial Networks ,GANs

En general hay dos clases de modelos en términos de machine learning, enfoques generadores o discriminadores. Los generadores intentan aprender de la distribución de parámetros de los datos y generar nuevos ejemplos a través de los modelos aprendidos. En cambio los discriminadores intentan modelar la dependencia de las etiquetas de los datos de formación, que pueden utilizarse para predecir la salida. Con un modelo de cada uno de los anteriores (G+D) se forman las GANs, donde el modelo G intenta generar entradas falsas lo más reales posibles y el modelo D intenta distinguir entre lo real y lo falso. Como observamos en la figura 5.13 se observa que se introduce un ruido aleatorio  $z$  al generador G y produce unos datos falsos  $G(z)$ . El generador está entrenado para minimizar  $\log(1-D(G(z)))$  Tras esto el discriminador D es entrenado para maximizar el  $\log(D(X))$ , que se corresponde con la probabilidad de asignar las etiquetas correctas a las muestras de prueba. Con todo esto se puede ver que el propósito de GAN es resolver el problema de minimización planteado en la ecuación 5.15, donde E se refiere a la previsión.

$$\min_G \max_D V(D, G) = E_{x \sim p(x)} [\log(D(x))] + E_{z \sim p(z)} [\log(1 - D(G(z)))] \quad (5.15)$$

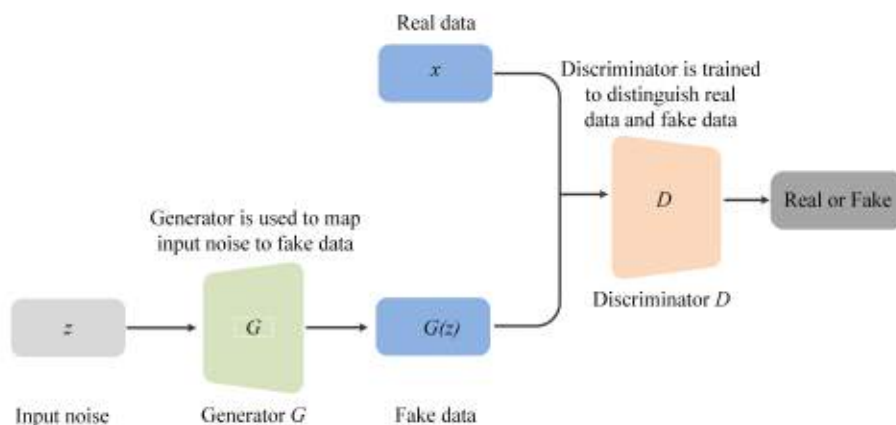


Figura 5.13: Esquema general de GAN [42].

Gracias a los avances en las redes convolucionales (CNN) se han creado redes convolucionales con arquitectura GAN, usando las CNNs en G y D. Este tipo de clasificador no es eficiente cuando hay muchas clases, ya que el discriminador solo diferencia lo falso de lo real. Por esa razón se han investigado técnicas para usar este tipo de redes en clasificación, como por ejemplo modificar D convirtiéndolo en un clasificador softmax que puede tener de salida varias probabilidades de las diferentes clases. En la figura 5.14 podemos ver una propuesta de clasificador HSI basado en una arquitectura GAN, donde se introducen etiquetas reales ( $c$ ) al generador además del ruido aleatorio ( $z$ ). Tras esto las muestras entrenadas con las etiquetas de clase correspondientes y los datos falsos generados en G son la entrada del discriminador D.

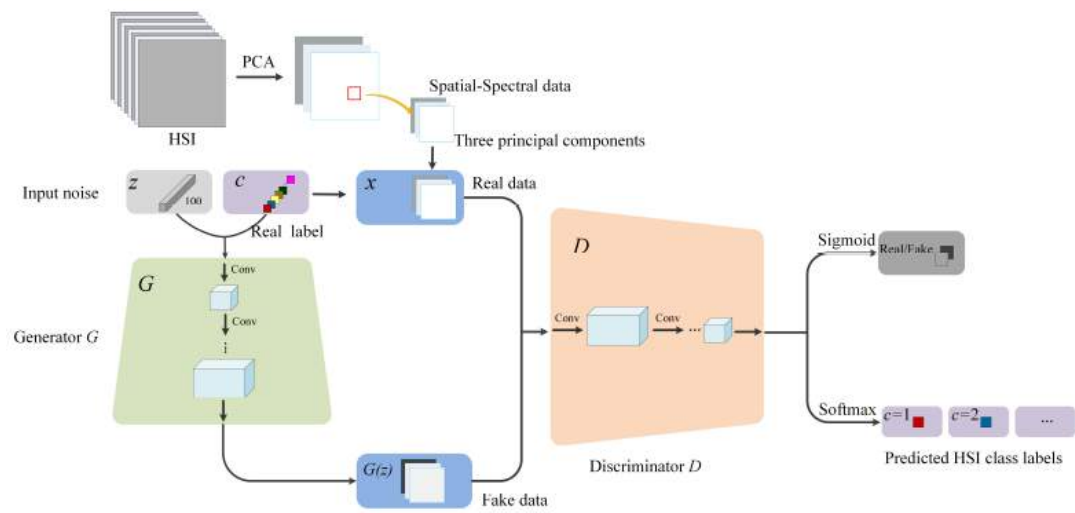


Figura 5.14: Clasificador para imágenes hiperespectrales basado en GAN [42].

# 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] C.F Romero. “La I + D en Defensa y Seguridad ”. En: (2013).
- [7] 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).
- [8] E. SánchezBernabé. “Procesado de imágenes hiperespectrales”. En: (2016). URL: <http://oa.upm.es/44860/>.
- [9] G. Wedell. “Employment issues in Europe in the 1980s. Librería USGS”. En: (1980).
- [10] C. Chang. *Real-Time Progressive Hyperspectral Image Processing*. 2016.
- [11] A. Cisz. “Performance comparison of hyperspectral target detection algorithms”. En: (2006).
- [12] A. Pose. “Adquisición, procesamiento y análisis de imágenes hiperespectrales: de la microscopía de fluorescencia a la industria satelital”. En: (2017).
- [13] M. M Crawford. X. Jia B.C Kuo. “Feature mining for hyperspectral image classification”. En: *Proceedings of the IEEE* 101 (2013).
- [14] 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).
- [15] 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>.
- [16] D. Manolakis y G. Shaw. “Detection algorithms for hyperspectral imaging applications”. En: *IEEE Signal Processing Magazine* 19 (2002).
- [17] 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).

- [18] 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).
- [19] A. Villalobos Pinzón. “Procesamiento digital de imágenes hiperespectrales”. En: (2017).
- [20] R. Scafutto y C. Filho. “Detection of methane plumes using airborne midwave infrared (3-5  $\mu\text{m}$ ) hyperspectral data”. En: *Remote Sensing* 10 (2018).
- [21] J. C Valdiviezo Navarro. “Segmentación de Imágenes Hiperespectrales usando Memorias Asociativas Morfológicas ”. En: (2007).
- [22] A. Plaza. “Procesamiento paralelo de imágenes hiperespectrales”. En: (2017).
- [23] 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).
- [24] H. Grahn P. Geladi y J. Burger. “Hyperspectral Imaging : Background and Equipment”. En: *Techniques and Applications of Hyperspectral Image Analysis* (2007).
- [25] C. Gonzalez Calvo. “Procesamiento a bordo de imágenes hiperespectrales de la superficie terrestre mediante hardware reconfigurable”. En: (2011).
- [26] M. Moore. *Hyperspectral Remote sensing*. 2016.
- [27] *Sentinel-2 - Missions - Sentinel Online*. URL: <https://sentinel.esa.int/web/sentinel/missions/sentinel-2>.
- [28] C. Lora A. José y J. Sánchez. “Diferente Resolución Espectral En La Exploración Minera”. En: (2016).
- [29] *Geo-soluciones Aster*. URL: <https://www.geosoluciones.cl/aster/>.
- [30] *GeoSpatial - Satélite WorldView-3*. URL: <http://www.geospatial.com.co/imagenes-de-satelite/worldview-3.html>.
- [31] *AVIRIS - Airborne Visible / Infrared Imaging Spectrometer*. URL: <https://aviris.jpl.nasa.gov/>.
- [32] G. Thf. “Summaries of the Fifth Annual JPL Airbone Earth Science Workshop”. En: (1995).
- [33] *ROSIS — Center for Remote Sensing (CRS)*. URL: [https://crs.hi.is/?page{\\\_}id=877](https://crs.hi.is/?page{\_}id=877).
- [34] *Hyperspectral Imaging Cameras — Hyperspectral Imaging Systems — Hyperspectral Machine Vision*. URL: <https://resonon.com/hyperspectral-cameras>.
- [35] *Imagen f180627t01p00r05rdn e sc01 ort img*. URL: [https://aviris.jpl.nasa.gov/alt\\_locator/](https://aviris.jpl.nasa.gov/alt_locator/).
- [36] *Introduction to K-means Clustering*. URL: <https://www.datascience.com/blog/k-means-clustering>.
- [37] *The 5 Clustering Algorithms Data Scientists Need to Know*. URL: <https://towardsdatascience.com/the-5-clustering-algorithms-data-scientists-need-to-know-a36d136ef68>.
- [38] 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).
- [39] 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).

- 
- [40] 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).
- [41] *ToolBox usada para sparse regression*. URL: <http://www.lx.it.pt/~bioucas/publications.html>.
- [42] B. Le Saux N. Audebert y S. Lefèvre. “Deep Learning for Classification of Hyperspectral Data: A Comparative Review”. En: (2019). URL: <http://arxiv.org/abs/1904.10674>{\% }0A<http://dx.doi.org/10.1109/MGRS.2019.2912563>.