



Universidad
de Alcalá

**ESTIMACIÓN DE SUPERFICIES MEDIANTE IMÁGENES
HIPERESPECTRALES SATELITALES Y AEROTRANSPORTADAS**

**SURFACE ESTIMATION USING HYPERSPECTRAL SATELLITE AND
AIRBORNE IMAGERY**

Máster Universitario en Tecnologías de la Información Geográfica

Presentado por:

D. José Antonio Gámez García

joseantoniogamezgarcia@gmail.com

Dirigido por:

Tutora académica:

Dra. Patricia Oliva Pavón

patricia.oliva@uah.es

Tutor de empresa:

Dr. Danielle Cerrá

Daniele.cerra@dlr.de

Alcalá de Henares, a 17 septiembre de 2024

D./D^a. Patricia Oliva Pavón

CERTIFICA:

Que el trabajo titulado: Estimación de superficies mediante imágenes hiperespectrales satelitales y aerotransportadas, ha sido realizado bajo mi dirección por el alumno/a D./D^a José Antonio Gámez García.

Alcalá de Henares, a de 17 de septiembre de 2024

Firmado:

**FORMULARIO DE AUTORIZACIÓN PARA LA INCLUSIÓN DEL TRABAJO DE FIN DE MASTER EN
EL ARCHIVO ABIERTO INSTITUCIONAL E-BUAH DE LA UNIVERSIDAD DE ALCALÁ.**

TÍTULO DEL TRABAJO FIN DE MASTER:
--

1.-ESTUDIANTE (AUTOR)

APELLIDOS Y NOMBRE: José Antonio Gámez García	DNI: 54238343L
TITULACIÓN: Master Universitario en Tecnologías de la Información Geográfica	

2.- DIRECTOR DEL TRABAJO FIN DE MASTER:

APELLIDOS Y NOMBRE: Patricia Oliva Pavón	DNI: 50986022J
DEPARTAMENTO o INSTITUCIÓN: Departamento de Geología, Geografía y Medio ambiente	

Los abajo firmantes:

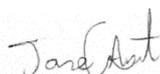
<input checked="" type="checkbox"/>	AUTORIZAN
<input type="checkbox"/>	NO
<input type="checkbox"/>	AUTORIZAN
<input type="checkbox"/>	NO
<input type="checkbox"/>	AUTORIZAN
<input type="checkbox"/>	DURANTE UN
<input type="checkbox"/>	PERIODO DE:
<input type="checkbox"/>	6 MESES
<input type="checkbox"/>	12 MESES
<input type="checkbox"/>	18 MESES
<input type="checkbox"/>	24 MESES

El depósito y puesta a disposición del Trabajo Fin de Máster en el Repositorio Institucional de la Universidad, e-BUAH, de acceso libre y gratuito a través de Internet, y otorgando las condiciones de uso de la licencia Creative Commons *reconocimiento-uso no comercial-sin obra derivada*.

Más información en: <http://creativecommons.org/licenses/by-nc-nd/3.0/deed.es>

Firmado: El autor

Firmado: El director del Trabajo Fin de Máster



<https://ebuah.uah.es/dspace/>

Los datos personales recogidos serán tratados por la Universidad de Alcalá con la finalidad de gestionar su autorización para la inclusión del Trabajo de Fin de Máster en el Archivo Abierto Institucional e-BUAH de la Universidad y su acceso libre a través de Internet, así como con fines estadísticos. La base legítima de dicho tratamiento es la ejecución de su autorización, las obligaciones legales en materia educativa y de investigación, así como su consentimiento expreso. Más allá de la publicación en el citado Repositorio, los datos no serán cedidos salvo los casos previstos legalmente y se conservarán durante el tiempo legalmente establecido y el necesario para cumplir con la finalidad descrita. El órgano responsable del tratamiento es la Secretaría General de la Universidad, ante quien se podrán ejercer los correspondientes derechos, mediante escrito dirigido a la Delegada de Protección de Datos (Colegio de San Ildefonso, Plaza de San Diego, s/n. 28801 Alcalá de Henares. Madrid) o por correo electrónico (protecciondedatos@uah.es), adjuntando copia del DNI o equivalente. En caso de conflicto, se podrá plantear recurso ante la Agencia Española de Protección de Datos. Para una información más detallada puede consultarse la Política de Privacidad de la Universidad.

MÁSTER EN TECNOLOGÍAS DE LA INFORMACIÓN GEOGRÁFICA

TRABAJO DE FIN DE MÁSTER (EMPRESA)

ESTIMACIÓN DE SUPERFICIES MEDIANTE IMÁGENES
HIPERESPECTRALES SATELITALES Y AEROTRANSPORTADAS

Tribunal de calificación:

Presidente: _____

Vocal 1º: _____

Vocal 2º: _____

Calificación: _____

Fecha: _____

Estimación de superficies mediante imágenes hiperespectrales satelitales y aerotransportadas

José Antonio Gámez García

Antonio.gomez@edu.uah.es

RESUMEN:

Los satélites hiperespectrales ofrecen características espectrales mejoradas comparadas con los satélites multiespectrales tradicionales. Recientemente, nuevos satélites hiperespectrales han sido lanzados, por lo que se desconoce la capacidad de estos satélites en cuanto a la clasificación de coberturas terrestres. Este trabajo analiza la eficacia de los sensores hiperespectrales HySpex (aeroportado), EnMAP y DESIS en la estimación de superficies en áreas urbanas. Su aplicación se ha basado en dos zonas urbanas en Munich, en una se consideró un elemento de importantes dimensiones y en la segunda se analizaron elementos de reducidas dimensiones. La investigación se centra en la comparación de la precisión de HySpex, con su alta resolución espacial (1 metro), con DESIS y EnMAP, ambos sensores satelitales con menor resolución espacial (30 metros).

Los resultados indican un mejor rendimiento de Hypspx, aunque con problemas relativos a efectos de reflexión, al igual que un inesperado mejor rendimiento de DESIS frente al recién lanzado satélite EnMAP. Este trabajo compara dos metodologías, utilizando un método manual de extracción de endmembers y un método automático. Aunque los métodos manuales presentan mayor precisión, los automáticos han demostrado ser útiles en escenarios con menor mezcla espectral.

PALABRAS CLAVE: Teledetección, Sensores hiperespectrales, EnMAP, DESIS, Hypspx, Estimación de superficies, Píxeles puros, desmezclado espectral.

ABSTRACT:

This paper analyzes the effectiveness of the HySpex, EnMAP, and DESIS hyperspectral sensors in estimating surfaces in urban areas. Its application was based on the measurement of a large element and a series of smaller elements in Munich. The research focuses on comparing the accuracy of HySpex (airborne sensor), with its high spatial resolution (1 meter), against DESIS and EnMAP, both satellite sensors with lower spatial resolution (30 meters).

The results indicate better performance from HySpex, though with issues related to reflection effects, as well as an unexpectedly better performance from DESIS compared to the newly launched EnMAP satellite. Two methodologies were also compared: a manual *endmember* extraction method and an automatic method. Although the manual methods showed greater accuracy, the automatic ones proved useful in scenarios with less spectral mixing.

Keywords: Remote sensing, Hyperspectral sensors, EnMAP, DESIS, Hypspx, Surface estimation, Pure Pixels, spectral unmixing.

ÍNDICE:

1. Introducción	7
2. Materiales y métodos	10
2.1 Área de estudio.....	10
2.2 Datos	11
2.3 Técnicas y métodos empleados.....	12
2.3.1 Selección y preprocesamiento de imágenes	13
2.3.2 Selección de píxeles puros	14
2.3.3 Generación de mapas de abundancia y cálculo de áreas	15
2.3.4 Validación de resultados	16
3. Resultados	17
3.1 Primera zona de estudio	17
3.2 Segunda zona de estudio	22
4. Discusión.....	25
5. Conclusiones	27
6. Referencias bibliográficas	28

1. Introducción

La teledetección, como una disciplina orientada a la observación terrestre, presenta posibilidades y limitaciones están estrechamente vinculadas al desarrollo tecnológico de nuevos sensores. En consecuencia, en un inicio las primeras imágenes históricamente tomadas se relegaban a fotografías capturadas por cámaras montadas en aviones a principios del siglo XX. Este tipo de imágenes, conocidas como ortofotografías, supusieron una enorme ventaja a la hora de estudiar el territorio, por las enormes posibilidades que ofrece disponer de una observación cenital del mismo (Martín et al, 2010).

Sin embargo, el mayor desarrollo de la teledetección se dará a partir de la década de los 60 y 70, con la creación de los programas de observación de la Tierra. Uno de los programas más exitosos ha sido Landsat, cuyo primer satélite fue lanzado en 1972 (Wulder et al., 2012). Su propósito radica en obtener imágenes de la superficie terrestre, para permitir estudios a mayor escala, a la vez que analizar los fenómenos y elementos terrestres con mayor profundidad. Posee el registro temporal más largo (más de 30 años desde su lanzamiento a la actualidad). Una de las mayores novedades de este satélite fue la inclusión de una cámara multiespectral, permitiendo mediante esta innovación captar información del espectro electromagnético más allá del visible y NIR. Junto a Landsat se sucedieron una serie de programas espaciales de interés como SPOT, Copernicus o EOS, cuyas características particulares posibilitaron diferentes tipos de análisis (National Research Council, 1998).

Restringiéndonos fundamentalmente a las imágenes multiespectrales, sus aplicaciones son muy diversas y se extienden a un amplio número de campos. Se pueden destacar el monitoreo ambiental (Chuvienco, 2010), vegetación (Petorelli, 2005), cuerpos de agua (Pekel, 2016), clasificación de coberturas (Sánchez-Hernández, 2007), detección de cambios (Martínez, 2009), al igual que de fenómenos dinámicos como incendios (Chuvienco, 1988) o inundaciones (García-Pintado, 2009). No obstante, las imágenes proporcionadas por este tipo de sensores están compuestas por un número limitado de bandas, en las que se comprime todo el espectro electromagnético. Aunque esto simplifica los datos y reduce su peso, se pierde mucha resolución espectral, lo que impide analizar detalles específicos que permitirían diferenciar ciertos elementos o extraer información más sutil.

Ante este problema, surgieron posteriormente sensores hiperespectrales o espectrómetros. Estas cámaras son capaces de capturar el espectro electromagnético en un gran número de bandas contiguas, permitiendo detectar una mucha mayor diversidad entre los elementos que componen la corteza terrestre (Goetz et al., 1985). A diferencia de las imágenes multiespectrales, los espectrómetros son capaces de captar la respuesta electromagnética de las superficies ofreciendo un espectro continuo. En este último concepto se halla el mayor interés de este tipo de imágenes, ya que permite distinguir coberturas similares mediante diferencias sutiles, como picos de reflectividad o bandas de absorción (Shen-En et al, 2023).

Pese a ello, existen limitaciones actuales en este tipo de imágenes como el derivado del cociente señal-ruido (magnitud de la señal dividido por la cantidad de ruido de esta) más bajo que en imágenes multiespectrales. A mayor ruido, los resultados serán más pobres y será más difícil extraer aspectos sutiles que diferencian un material de otro. Frente a esto, existen técnicas para reducir la dimensionalidad de la imagen y el ruido de esta, como la aplicación de “Main Components” o “Minimum Noise Fraction” (Shen-En et al, 2023).

El origen de los espectrómetros se ubica en Estados Unidos durante los años 80, restringiéndose principalmente a campañas de vuelo en sus primeros años. No sería hasta el año 1990 cuando se iniciaría la primera misión satelital hiperespectral, Hyperion, estando en activo durante hasta 2016. Su larga duración supuso una muy importante contribución al desarrollo

tecnológico de dichos sensores y de una comunidad científica que trabaje en sus diferentes aplicaciones. Sucediendo a esta misión, recientemente se lanzaron tres satélites hiperespectrales de desarrollo europeo, PRISMA (Agencia Espacial Italiana), DESIS (en cooperación con Teledyne) y EnMAP (Agencia Espacial Alemana, DLR). Esta nueva generación supuso una mejora en el cociente señal-ruido, proporcionando además una cobertura del espectro más amplio y una mejor resolución espectral (Foerster et al, 2019).

Algunos ejemplos de aplicaciones de las imágenes hiperespectrales son, el análisis de la salud de la vegetación a través de la clorofila (Zarco-Tejada, 2001), detección de plagas en cosechas (West, 2003), detección de minerales (Van der Meer, 2012) o cartografía de coberturas urbanas (Heiden, 2007). Estos ejemplos ilustran como la potencialidad de este tipo de sensor está relacionada con su capacidad de detectar diferencias sutiles, que muchas veces se puede reducir a una banda de absorción, no observable en sensores multispectrales. Actualmente las imágenes hiperespectrales se obtienen principalmente a partir de campañas de vuelo, las cuales poseen una mucha mejor resolución espacial, generalmente de alrededor de un metro. Por ello, el reciente lanzamiento de los sensores hiperespectrales abre muchas posibilidades con las que aún se debe trabajar, pero con limitaciones marcadas por una menor resolución espacial (Foerster et al, 2019).

La resolución espectral no es el único factor para tener en cuenta en la información explotable de una imagen. Las cámaras instaladas en satélites deben hacer frente a un balance de resolución espacial y extensión cubierta en sus imágenes, debiendo equilibrar ambas para maximizar la utilidad de los datos obtenidos. Así, tanto la altura de un satélite como su FOV condicionan su tamaño de píxel, siendo frecuente en satélites hiperespectrales un tamaño de píxel de 30 metros. (EnMAP, DESIS, PRISMA ...). El tamaño de píxel tiene una importante repercusión en la imagen final, condiciona la relación píxel-objeto y por ello la escala de análisis, como se observa en la figura 1. Así, en cada una de las celdillas de la imagen ENMAP hay 900 metros cuadrados, lo que implica una potencial presencia de múltiples coberturas y por ende una respuesta espectral mezclada. Este hecho no es un problema tan evidente en muchas áreas naturales, generalmente con un carácter más homogéneo, pero sí en áreas antrópicas, donde se da una presencia de usos mucho más intensiva. Debido a ello, el tema de clasificación de píxeles ha sido un tema muy tratado por la comunidad de la teledetección en las últimas décadas (Myint et al, 2015).

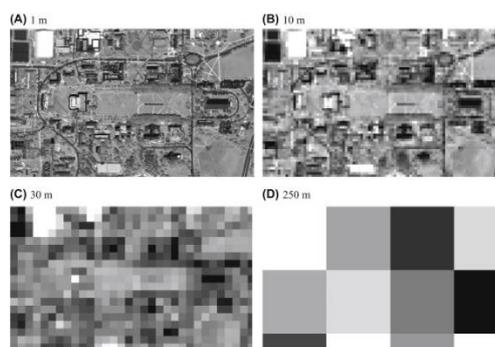


Figura 1: Relación objeto-píxel en diferentes coberturas de análisis.
Figura tomada de Li et al. (2012)

Esto ha supuesto el desarrollo de diferentes métodos para aproximar esta problemática. Por lo general en las clasificaciones (a menos que tengan un carácter exploratorio), es necesario aportar píxeles puros para cada categoría de la clasificación. Los píxeles puros hacen referencia a un espectro que representa una cobertura sin ninguna mezcla, perteneciente a un único material. A la hora de clasificar una imagen, el proceso de obtención de píxeles puros resulta arduo, ya que su elección condiciona en sobremanera los resultados finales, por lo que es fundamental una buena elección (Myint et al, 2015).

Actualmente existen librerías espectrales a partir de firmas medidas en laboratorio, pero en muchos casos se necesita medir coberturas específicas que no están disponibles en estos repositorios. Se puede también acudir a un criterio visual y seleccionar píxeles sobre la propia imagen, en función de lo que se quiera clasificar. Aunque en imágenes de resolución media se presentan contextos heterogéneos en los que la selección puede ser confusa. Frente a ello, existen métodos automáticos de extracción de píxeles puros como N-FINDR, Pixel Purity Index o Vertex Component Analysis, que aportan las firmas espectrales más puras en el contexto de la imagen utilizada (Ozcan et al, 2023).

Junto a la selección de píxeles puros, existen dos aproximaciones a como se clasifica el píxel. En un primer nivel se halla la clasificación por píxeles. En este caso la escala es un factor fundamental en los resultados, ya que condiciona la especificidad del tipo de coberturas a identificar, al igual que la precisión de los usos urbanos. Esta aproximación conlleva una clasificación “estricta”, es decir, que cada píxel sólo puede corresponder a una cobertura. En contextos urbanos esta aproximación es irrealista, ya que rara vez se da una sola cobertura en un mismo píxel, provocando resultados que tienden a sobreestimar dichas áreas. Algunos de los métodos más interesantes son la máxima probabilidad, máquinas vector soporte o redes neuronales (Myint et al, 2015).

En un segundo nivel se halla la clasificación a nivel subpíxel. Este método busca identificar las mezclas espectrales representando diferentes coberturas en cada uno de los píxeles. En este caso la clasificación sería “flexible o adaptativa” ya que un mismo píxel no se halla constreñido a una sola cobertura, por lo que resulta en una aproximación mucho más realista al contexto urbano. Existen diversos métodos para aplicar la clasificación subpíxel, aunque en este caso todos tienen un objetivo común, extraer la proporción de cada píxel puro en todos los píxeles (Myint et al, 2015).

Una de las metodologías más interesantes en esta escala de clasificación son las técnicas de desmezclado espectral. Mediante la combinación lineal de una serie de firmas de interés, es posible determinar su contribución porcentual de cada uno en los píxeles analizados. En la figura 2, se presenta un ejemplo donde se puede observar cómo la mezcla de diferentes coberturas superficiales corresponde a la combinación de cada una de las firmas espectrales presentes, permitiendo así realizar el proceso inverso para identificar su proporción en el píxel correspondiente. A raíz de esta técnica, se puede calcular también la abundancia de cada píxel puro, pudiendo así estimar la superficie de coberturas en espacios heterogéneos, como por ejemplo edificios o vías urbanas (Ceamanos, 2016).

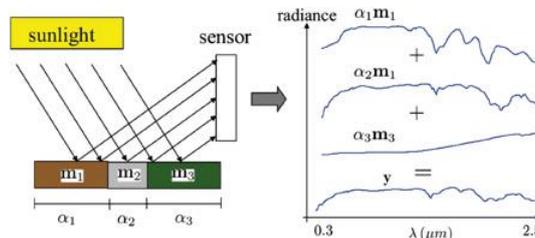


Figura 2: Ejemplo de aplicación de técnicas de desmezclado espectral
Fuente: Ceamanos, 2016

Sin embargo, el desmezclado espectral posee limitaciones en cuanto a su efectividad en áreas heterogéneas, con relación a las características del sensor:

- El tamaño del píxel debe ser pequeño: ante la naturaleza heterogénea de las áreas urbanas (Myint et al, 2015).
- La resolución espectral debe ser alta: debido a que esta técnica proporciona mejor según mayor sea la relación del número de bandas y los píxeles puros. Junto a ello, clasificar

áreas urbanas requiere por lo general, un mayor número de píxeles puros, por lo que las imágenes multispectrales poseerían una aplicación muy reducida (Myint et al, 2015).

Los espectrómetros por lo tanto son ideales para la aplicación de este tipo de análisis. Ya Hyperion mostró buenos resultados con esta técnica, superando en precisión a otros sensores multispectrales (Ferrato, 2013). La nueva generación de espectrómetros al poseer mejores especificaciones técnicas, son una excelente oportunidad para trabajar con este método y analizar la calidad de las imágenes. Este último aspecto resulta fundamental ya que, ante el reciente lanzamiento de estos satélites, se continúa investigando sus posibilidades y limitaciones.

Según el artículo publicado por Danielle Cerrá, donde se analiza la estimación de la superficie de parques solares en Alemania mediante técnicas de desmezclado espectral, se corroboran peores resultados del satélite multispectral Sentinel-2 frente a los espectrómetros DESIS y Hypspx (sensor aeroportado). También se menciona en dicho análisis, un error similar entre ambos espectrómetros, lo que indica un muy buen desempeño del reciente satélite DESIS a pesar de su menor resolución espacial (Cerrá, 2022).

Estos resultados abren el interés de analizar con más profundidad las posibilidades de los nuevos sensores hiperespectrales satelitales, frente a los más tradicionales espectrómetros aeroportados. Además, resultaría beneficioso conocer su potencialidad en entornos urbanos, tanto por su diferente relación píxel-objeto como resolución espectral. EnMAP en especial, al ser un satélite lanzado recientemente, sus posibilidades aún no han sido estudiadas en profundidad.

En el marco de este trabajo de final de máster se busca continuar en esta línea, a través del análisis del desempeño de los espectrómetros satelitales (DEGIS, EnMAP) y aeroportados (Hypspx), en la medición de superficies en áreas urbanas. A raíz del objetivo general se establecen una serie de objetivos específicos:

- Comparación del comportamiento y precisión de algoritmos de medición de superficie en sensores hiperespectrales de diferente resolución espacial.
- Comparación de resultados obtenidos con píxeles puros manuales o automáticos.

2. Materiales y métodos

2.1 Área de estudio

El ámbito de estudio se centra en Múnich (Alemania) ya que es de donde se disponen las imágenes de los tres sensores hiperespectrales. Aunque las proporcionadas por Hypspx ocupan una cobertura espacial mucho menor, reduciéndose al norte de la ciudad. Sin embargo, esta zona de la ciudad resulta ideal para este estudio al encontrarse en los suburbios, conteniendo zonas residenciales, áreas verdes, además de zonas industriales y grandes edificios. El análisis, va a estar constreñido a dos áreas de estudio, con una dimensión mucho más reducida al de las propias imágenes, con el fin de ser computacionalmente eficientes y para poder analizar elementos concretos.

La primera zona corresponde al Allianz Arena (figura 3), el principal estadio de fútbol de la ciudad, del cual se pretende medir su anillo exterior (se excluye el césped interior). Debido a sus largas dimensiones, lo hace un elemento individual ideal para estimar su superficie. La perspectiva cenital posibilita ver el tejado oval del estadio, cuya forma resulta de interés por los efectos que puede causar en la reflectancia de los píxeles. Por otro, la estructura está compuesta por diversos materiales, lo que genera importantes diferencias en los diferentes criterios selección de píxeles puros y la superficie final. Además, se incluyen otras coberturas que se deben discriminar para que en el proceso se calcule correctamente la superficie del estadio, como son el césped del estadio, como toda el área exterior.



Figura 3: Primera y segunda área de estudio.

Fuente: Sensor pancromático 3k (obtenido de la base de datos MultiMUC)

La segunda zona corresponde con un área residencial en el distrito de Hansenbergl-Feldmoching. Se pretende medir los edificios alargados de techo rojo que se hallan en el entorno del parque urbano. En este caso se miden una serie de construcciones que, aunque a nivel visual parezcan similares, pueden variar en su firma espectral. En este caso los objetivos a medir no son tan grandes, por lo que el desmezclado espectral a priori puede ser algo más complejo, por la mezcla de usos mismo píxel.

2.2 Datos

Todos los datos utilizados forman parte de una base de datos llamada MultiMUC, en propiedad de la Agencia Aeroespacial Alemana (DLR). Su contenido aún no es de acceso libre, ya que está en proceso de confección, siendo su principal objetivo aplicar técnicas de fusión de datos, además de analizar las posibilidades de las imágenes de EnMAP. El acceso para este Trabajo de Fin de Máster ha sido posible gracias a las prácticas realizadas en el propio DLR.

La fecha de la captura de las imágenes se da entre el primer trimestre de 2022 y el último de 2023. Los siguientes sensores están contenidos dentro de la base de datos:

- Sensores multiespectrales: Sentinel 2 y Landsat 8.
- Sensores hiperespectrales satelitales: EnMAP y DESIS.
- Sensores hiperespectrales aerotransportados: Hypspx.
- Cámaras pancromáticas aerotransportadas: 3K.
- Radars satelitales: Sentinel 1, TerraSAR-X / TanDEM-X.

De todos estos datos se utilizarán las imágenes de EnMAP, DESIS y Hypspx para el análisis. Para la validación de los resultados se utilizará las imágenes aportadas por la cámara 3K, debido a su resolución espacial centimétrica. En la tabla 1 se proporcionan los detalles de más interés de cada sensor hiperespectral.

Tabla 1: información de mayor relevancia de sensores hiperespectrales

Fuente: datos extraídos de MultiMUC

Satélite	Cobertura espectral	Resolución espectral	N° de bandas	Resolución espacial	Cociente señal-ruido promedio
EnMAP	420-1000 nm (VNIR) 900-2450 nm (SWIR)	6.5 nm 10 nm	246	30 m	> 400:1 (VNIR) >170:1 (SWIR)
DESI	400-1000 nm (VNIR)	2.5 nm	235	30 m	>195:1 (VNIR)
Hypspx	416-992 nm (VNIR) 968- 2498 nm (SWIR)	3.6 nm 6 nm	583	1 m	>180-900 (VNIR) >1000 (SWIR)

El sensor más antiguo de todos es Hypspx, desarrollado por la empresa noruega Norsk Elektro Optikk y utilizado por primera vez en 2003. Este sensor cuenta con un gran número de

bandas que abarcan desde los 416 hasta los 2498 nanómetros en el espectro electromagnético, con una resolución espacial un metro. Además, su relación señal-ruido es alta, alcanzando aproximadamente 1:1000 en condiciones favorables, lo que proporciona una mayor precisión en el análisis de sus datos (IMF, 2016). El mayor interés de Hypspx radica en su larga trayectoria y en su mayor resolución espacial, lo que permite utilizar sus resultados a modo de comparación con DESIS y en espacial EnMAP, pudiendo así analizar el rendimiento de ambos sensores.

Por otro lado, el sensor DESIS (DLR Earth Sensing Imaging Spectrometer) está instalado en la plataforma MUSES, en la Estación Espacial Internacional. Es considerado un precursor de EnMAP, ya que ambos comparten el mismo sensor en el infrarrojo cercano. Una de las características más destacadas de DESIS, que lo diferencia de EnMAP, es su ángulo de observación respecto a la Tierra, de 15 grados, junto con la menor anchura de bandas espectrales. Estas diferencias permiten estudiar cómo varían los resultados de un mismo sensor bajo distintas condiciones técnicas (Müller, 2018).

Finalmente, EnMAP (Environmental Mapping and Analysis Program), satélite lanzado en 2022, empezó ya a tomar imágenes dos meses tras su lanzamiento. Representa un avance respecto al proyecto realizado con DESIS en la Estación Espacial Internacional. Su principal mejora radica en un rango espectral más amplio, similar al de Hypspx, lo que permite una mayor capacidad de análisis (Storch et al., 2023).

Cada uno de los sensores tiene un cociente señal-ruido promedio diferente, aspecto que va a condicionar resultados de diferente precisión. Así Hypspx posee un sensor en el VNIR muy sujeto a variaciones (en función de las condiciones atmosféricas), pero el cual puede llegar a tener un cociente mucho más alto que DESIS o EnMAP, lo que permite extraer diferencias más sutiles entre los materiales. A pesar de ello EnMAP como recién satélite lanzado, parece poseer un mejor cociente señal-ruido que DESIS en el VNIR, lo que a priori, le permitiría extraer mejores resultados de imágenes en contextos heterogéneos. En el espectro del SWIR, sin embargo, EnMAP encuentra un cociente muy bajo en relación con Hypspx, aspecto que podría ser fundamental en los resultados, ya que esta franja del espectro permite diferenciar elementos urbanos muy similares. Esto permitiría diferenciar varios tipos de materiales dentro del objetivo a medir (Ilehag et al., 2019).

2.3 Técnicas y métodos empleados

Para cumplimentar los objetivos tratados, se han producido una serie de mapas de abundancia a través de técnicas de desmezclado espectral. Para ello, se han seguido los pasos mostrados por la figura 4. En primer lugar, se extraen de la imagen los *endmembers* que van a representar los elementos de la imagen a clasificar. Se ha realizado una doble selección de *endmembers*, una de manera automática y otra manual, para observar la diferencia en el resultado final de la medición. A continuación, se realiza la combinación de los mapas de abundancia para finalmente generar la cartografía de la imagen clasificada en las categorías de interés.

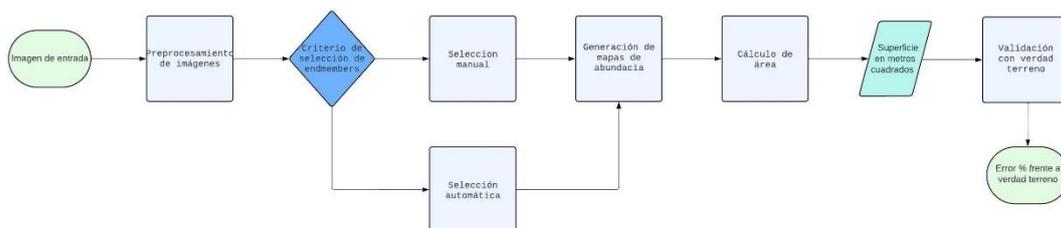


Figura 4: Diagrama de flujo sobre la metodología de trabajo
Fuente: Elaboración propia.

Para el desarrollo de la metodología se ha trabajado principalmente con los siguientes softwares: ENVI, QGIS y ArcGIS Pro. Aunque estas aplicaciones se han utilizado meramente para visualizar resultados y realizar interpretaciones a partir de estos. La metodología se ha aplicado fundamentalmente a través de Python, utilizando principalmente las siguientes librerías:

- SPy: “Spectral Python” es una librería utilizada para la manipulación de imágenes hiperespectrales, permite su lectura, escritura, y aplicar algunos algoritmos.
- Pysptools: Pysptools es una librería que contiene multitud de algoritmos de procesamiento de imágenes hiperespectrales.
- Arcpy: Utilizado para aplicación de geoprocursos diversos.
- GDAL: para operaciones y procesos más simples, como normalizar imágenes o eliminar bandas malas.

2.3.1 Selección y preprocesamiento de imágenes

El primer paso es la selección de las imágenes sujetas a análisis. Este paso es primordial debido a que es necesario que posean un intervalo temporal corto y a una hora similar, garantizando así su comparabilidad. Se debe tomar en cuenta también las condiciones técnicas de adquisición, ya que tanto EnMAP como DESIS poseen distintos tipos de órbitas. Se asume que van a existir unas ciertas diferencias en los valores de reflectividad resultantes, aunque se aplican las mismas rutinas y formatos de producto para facilitar la combinación de ambos productos, permitiendo así su uso conjunto (Storch & Müller, 2017) .

Todas las imágenes utilizadas corresponden al nivel de procesamiento L2A (productos corregidos atmosféricamente y con valores de reflectividad). En todo el proceso, se observó que en dos imágenes de EnMAP la precisión geométrica era un poco peor de lo esperado, resultado de algunos problemas en el procesado de imágenes en el nivel L1. Además, las imágenes no contenían en su información de cabecera la información relativa a su ancho de banda ni su anchura a media altura (FWHM). Por lo que fue necesario obtener estos datos a través de un código que buscara en los metadatos la información para cada banda. Esto se hizo a través de la librería “Element Tree”, que permite realizar estas búsquedas de manera sencilla a través de un método jerárquico en XML. Finalmente, se aplicaron los metadatos obtenidos a las imágenes, pudiendo ya proceder.

En la tabla 2 se indican las imágenes elegidas y sus principales condiciones de adquisición. Las fechas se hallan en un mes y hora próximos, resultando en una diferencia de azimuth del sol de no más de 20 grados entre DESIS y Hypex. Sin embargo, esta diferencia es importante en zonas urbanas, debido a que, por la verticalidad de las estructuras y la presencia de diferentes materiales, variaciones de más de cinco grados provocan que las imágenes sean difíciles de comparar por cambios en la sombra e iluminación de los píxeles (Wang, 2022). Por ello en este trabajo las técnicas de fusión de datos van a ser complejas de aplicar, aunque si es posible continuar con estas imágenes debido a que la metodología se aplicará individualmente a cada una de ellas.

Tabla 2: imágenes elegidas para medición de superficies
Fuente: datos extraídos de MultiMUC

Satélite	Fecha	Hora	Órbita	Azimuth Sol
EnMAP	2023/09/29	10:46	Descendiendo	174 °
DESI	2021/10/18	11:21	Descendiendo	186 °
Hypex	2023/09/21	10:26	-	166 °

Otro aspecto en el preprocesado es la eliminación de bandas malas, resultado de fallos sistemáticos del sensor o bandas de absorción de la atmósfera. Con DESIS fue necesario eliminar

las primeras y últimas bandas, ya que poseían errores sistemáticos importantes, causando inestabilidad en la firma espectral resultante. Con EnMAP ocurre algo similar, teniendo que ignorar las primeras y últimas bandas por errores sistemáticos, y las bandas 130 a 135 (1330-1390 nanómetros) debido a la absorción del vapor de agua atmosférico. Además, en EnMAP, las últimas bandas del NIR y las primeras del SWIR se superponen, teniendo que eliminar parte de ellas para que la firma espectral sea más pulcra, y para que el algoritmo de desmezclado espectral no presente problemas al tener valores muy diferentes en una longitud de onda próxima. La imagen de Hypesx es la que más bandas malas ha tenido, debido a su alta dimensionalidad, presentando problemas especialmente en las primeras y últimas bandas.

2.3.2 Selección de píxeles puros

Una vez los datos con los que trabajar han sido preprocesados, el paso más importante consta de generar la librería de firmas espectrales a partir de la cual se va a generar el mapa de abundancia. Seleccionar píxeles puros implica identificar el número presente en la imagen, el tipo y sus correspondientes firmas espectrales. Su selección radica en proceso iterativo generalmente, donde se van probando diferentes conjuntos de firmas espectrales para observar su desempeño (Akbari et al, 2022) . En este caso todas las firmas se han extraído de la propia imagen a través de dos criterios:

- Análisis visual: búsqueda manual de los píxeles puros en la imagen. Relativamente sencillo en la imagen de Hypesx debido a que no hay tanta mezcla de coberturas. Sin embargo, en EnMAP y DESIS se requiere una observación detallada de los diferentes píxeles. Es un proceso arduo, ya que requiere diversos intentos hasta encontrar finalmente los píxeles puros adecuados. Para obtener buenos resultados, se ha requerido utilizar técnicas en conjunto, que otorguen información de la imagen. La principal ha sido, Píxel Purity Index (PPI), algoritmo utilizado en el análisis de imágenes hiperespectrales para identificar los píxeles más "puros" o extremos, es decir, aquellos que representan las firmas espectrales más distintas en una escena. Funciona realizando varias proyecciones aleatorias de los datos hiperespectrales en el espacio n-dimensional y midiendo la pureza de los píxeles según su distancia desde el centro de la proyección. Los píxeles con valores extremos en múltiples proyecciones se consideran candidatos a ser píxeles puros. Este índice es fundamental para la extracción de píxeles puros, ya que ayuda a seleccionar las firmas espectrales más representativas antes de aplicar algoritmos de desmezclado (Chein-I et al,2006).
- Aplicación de algoritmos de extracción de píxeles puros: en concreto el algoritmo SMACC (Sequential Maximum Angle Convex Cone), que permite identificar las firmas espectrales para la aplicación de este tipo de análisis. Funciona de manera secuencial, seleccionando los espectros más distintos mediante la maximización del ángulo espectral entre ellos y formando un cono convexo en el espacio espectral. El algoritmo termina cuando encuentra el número de espectros puros indicado que conforman el mayor volumen espectral, dando lugar a un conjunto de píxeles puros (Aggarwal et al, 2015).

Esta parte es la más compleja del análisis, pues es un proceso iterativo donde se van identificando qué elementos de la imagen no han sido bien representados y el porqué, intentando modificar la librería para mejorar el resultado final. Para lograr una mejor precisión, se crearon regiones de interés (ROI) en ENVI, donde se seleccionaron varios píxeles para cada firma espectral, y se obtuvo una media final. Este enfoque es más efectivo que seleccionar un solo píxel porque reduce el ruido en la señal, captura la variabilidad espectral del material y garantiza una mayor representatividad del área analizada. Además, tomar varios píxeles permite mitigar errores potenciales debidos a píxeles atípicos o interferencias, logrando una representación más precisa y estable del espectro del material. Este método es particularmente beneficioso en contextos

donde un solo píxel no representa adecuadamente un elemento, como ocurre en las imágenes de EnMAP y DESIS.

El proceso de selección de píxeles puros se ha podido aplicar de tanto forma manual como automática en la primera zona de estudio, sin embargo, la segunda área de trabajo ha dado problemas en los algoritmos automáticos. Esto no se ha observado en Hypspx, debido a que su alta resolución espacial permite al algoritmo encontrar fácilmente píxeles puros. Tanto EnMAP como DESIS ante su resolución espacial media (30 metros) presentan desafíos adicionales en la identificación de píxeles puros ya que se producen mezclas espectrales más complejas, lo que dificulta la tarea de selección. En estos casos, el análisis manual se convierte en una herramienta crucial para superar las limitaciones inherentes a la resolución espacial más baja. Por la dificultad en la aplicación de SMACC (aun aplicando técnicas de reducción de dimensionalidad), se ha omitido en la segunda zona de estudio en su aplicación en DESIS y EnMAP.

Como último aspecto a reseñar, se han seleccionado los píxeles puros en torno a la siguiente clasificación:

- Firmas espectrales artificiales: Estas son firmas espectrales que, aunque no corresponden al objetivo de medición, son espectralmente similares a las del objetivo. Su identificación es crucial porque pueden interferir con la detección precisa del objetivo.
- Firmas espectrales naturales: Estas firmas están asociadas con elementos naturales, como la vegetación. Son relativamente fáciles de identificar debido a sus características distintivas y diferenciadas.
- Firmas espectrales objetivo: Se refiere a las firmas espectrales que se utilizarán posteriormente para la medición del elemento de interés, en este caso zonas edificadas. Son las más relevantes para el análisis y la interpretación de los datos espectrales.

También se ha de considerar que la relación objeto-píxel en Hypspx es diferente a los sensores satelitales debido a su alta resolución espacial. Esta casuística provoca que la reflectancia de elementos no deseados empiece a aparecer. Además, es muy complejo elegir todos los píxeles puros posibles debido a la alta heterogeneidad presente en contextos urbanos (Myint et al, 2015). Por ello, se va a comparar también, el desempeño de Hypspx tanto en sus condiciones normales, como con un filtro de paso bajo. El filtro de paso bajo ayudaría a medir con mayor precisión el objetivo deseado, ya que reduce la complejidad provocada por la relación píxel-objeto en la clasificación de píxeles puros. Su aplicación se puede observar en la figura 5, utilizándose una ventana de 5 píxeles. Este filtro ayuda a integrar los paneles solares ubicados en los bordes del estadio, que podrían afectar la clasificación a pesar de su tamaño reducido. Además, en el área suroeste, que está parcialmente a la sombra, se observa un efecto de reflexión especular causado por la iluminación en la zona norte del estadio. El filtro de paso bajo también demuestra ser eficaz al suavizar este efecto reflejo.

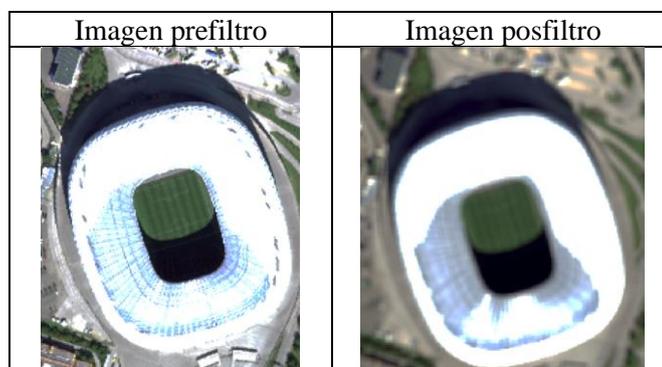


Figura 5: resultado la aplicación del filtro bajo en imagen de Hypspx
Fuente: datos extraídos de MultiMUC

2.3.3 Generación de mapas de abundancia y cálculo de áreas

Previamente al cálculo de áreas, es necesario generar un mapa donde se observe la proporción de cada píxel puro en cada uno de los píxeles. Para el desmezclado espectral, se ha utilizado la técnica de Non-Negative Constrained Least Squares (NNLS), el cual se basa en un problema de regresión en el que hay un alto ratio entre el número de objetos (píxeles puros) y las variables (bandas espectrales). Esta técnica es particularmente adecuada para imágenes hiperespectrales debido a su alta dimensionalidad. El modelo NNLS está restringido a valores no negativos, ya que no es realista que la proporción de una cobertura en un píxel sea negativa. Alternativamente, se podría utilizar Fully Constrained Least Squares (FCLS), donde la suma de las proporciones de todas las coberturas en un píxel está limitada a uno. Aunque esta restricción puede parecer razonable, FCLS presenta problemas al calcular la combinación lineal de todas las coberturas, ya que puede forzar la presencia de algunas coberturas en porcentajes muy pequeños (0.5%-2%) para cumplir con la restricción de que la suma total sea igual a uno.

Tras la aplicación del algoritmo se realizan algunos procesos para mejorar la calidad de los resultados. Se ha establecido un umbral mínimo del 5 % para la proporción de cada cobertura en el píxel. Este umbral se introduce para abordar el problema del ruido asociado con la alta dimensionalidad de la imagen. En imágenes hiperespectrales, el ruido puede hacer que las estimaciones de las proporciones de coberturas sean inexactas o inestables, especialmente cuando las concentraciones reales son muy bajas. Al imponer un umbral mínimo, se evita que el modelo asigne proporciones irrealmente bajas a las coberturas, lo que mejora la robustez y la fiabilidad de las estimaciones espectrales y ayuda a obtener resultados más consistentes y prácticos en la interpretación de las imágenes.

Tras esto, se combinan los píxeles puros en función de su clasificación dada, generando una cartografía los elementos objetivo en rojo, los artificiales en azul y los naturales en verde. Puede ocurrir que la suma de píxeles puros bajo su clasificación de más de 1 en algunos píxeles. Esto ha ocurrido especialmente en la imagen de Hypspx, donde muchos de los píxeles lumínicamente saturados daban resultados de entre 1 y 1.1. En esta situación este factor es de suma importancia debido a que, al utilizar la proporción para medir áreas, daría lugar a una sobreestimación. Por ello se ha limitado toda cifra mayor a 1.01 a 1.

2.3.4 Validación de resultados

Una vez se generan los mapas de abundancia, queda el último paso, medir el área. Aunque primero es necesario obtener una superficie de referencia de ambos elementos a medir, para poder establecer una verdad terreno con la que comparar. Para ello se ha utilizado el sensor pancromático 3k, que gracias a su muy detallada resolución espacial (37 centímetros), permite vectorizar con una alta precisión y obtener una referencia realista. En la figura 6 se puede observar el resultado de la digitalización, obteniendo para el primer caso el área total del polígono, y para el segundo caso la suma del área de todos los polígonos.

Para comenzar a calcular el área es necesario primero enmascarar a un entorno más próximo de lo que se quiere medir, evitando así que la mayor parte de los falsos positivos (parte de alguna construcción cercana u otras cubiertas) se sumen al área final. La banda relativa a la suma de píxeles puros clasificados como elemento objetivo ve multiplicado su valor en cada píxel por el tamaño de este. Al medir un objetivo, en el contexto de prácticas en el DLR, se decidió trabajar con una medida de error relativo porcentual, expresado en la ecuación 1.

$$\text{Error relativo porcentual (\%)} = \frac{\text{Resultado} - \text{Verdad Terreno}}{\text{Verdad Terreno}} \times 100.$$



Figura 6: Vectores utilizados para validación de resultados
Fuente: Elaboración propia

3. Resultados

En este apartado se van a analizar los principales productos generados durante el análisis, tanto librerías espectrales como mapas de abundancia y cálculo de área. A su vez este apartado se subdividirá en los resultados de las dos zonas de estudio, tratando ambos conjuntamente en el apartado de discusión. Se ha de reseñar que, aunque se seleccionen un diferente número de firmas espectrales para cada sensor, el objetivo es generar una clasificación basada en el elemento objetivo, vegetación y otros elementos urbanos (asfalto, otros edificios).

3.1 Primera zona de estudio

En la figura 7 se muestran las dos librerías espectrales utilizadas según el criterio de selección de píxeles puros con el sensor Hypspec. De los tres sensores utilizados, Hypspec es el que más firmas espectrales contiene, siete en ambos casos. Las firmas espectrales del asfalto (iluminado y en sombra) destacan por su baja reflectancia en casi todo el espectro, lo que es típico de superficies oscuras y altamente absorbentes como el asfalto. Las curvas del estadio (iluminado y en sombra) muestran una mayor variabilidad en el infrarrojo cercano, con picos que podrían indicar la presencia de césped (natural o artificial) en ciertas áreas

La segunda gráfica relativa a la extracción automática, introduce un tipo de vegetación diferente, que de manera manual no se ha considerado una firma espectral, al igual que un nuevo material de construcción. Ya a priori se observa la alta separabilidad espectral entre elementos naturales y antrópicos y a su vez la escasa diferencia entre los últimos. Esto se debe a que muchos materiales construidos, como el asfalto y otros materiales de construcción, tienden a tener firmas espectrales similares en gran parte del espectro visible e infrarrojo cercano. Sin embargo, con una alta resolución espectral, es posible realizar una diferenciación más precisa en el infrarrojo medio, donde algunas variaciones entre materiales pueden emerger debido a diferencias en la composición mineral o el tratamiento de la superficie. Distinguir esta gran variedad de materiales es posible además gracias a la alta resolución espacial de Hypspec.

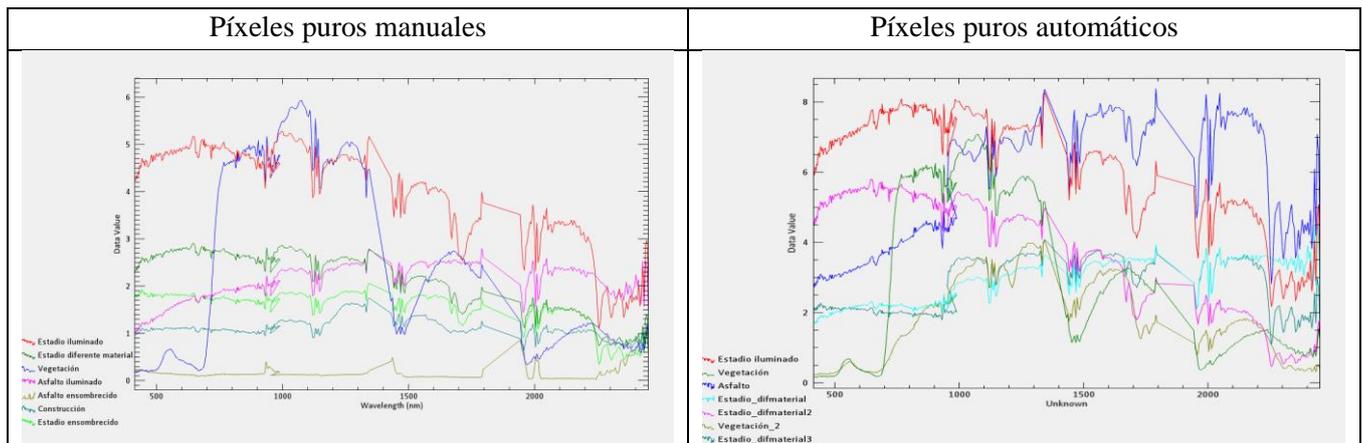


Figura 7: Librería espectral de los *endmembers* utilizados para elaboración del mapa de abundancia (primera área de estudio): Hypspx.

Fuente: Elaboración propia

La figura 6 muestra el resultado de la imagen clasificada a partir de la librería espectral ya reseñada. Los espectros seleccionados se reclasificaron en material objetivo, vegetación y elementos urbanos (Figura 8). Ambos criterios de selección de píxeles puros parecen proporcionar de manera general buenos resultados. Sin embargo, el segundo método presenta más problemas a la hora de captar todos los materiales del estadio, teniendo especialmente dificultades al no contar con el píxel puro de la sombra del estadio. Por lo que, a nivel general, el primer método parece captar mejor las dimensiones del elemento a medir.

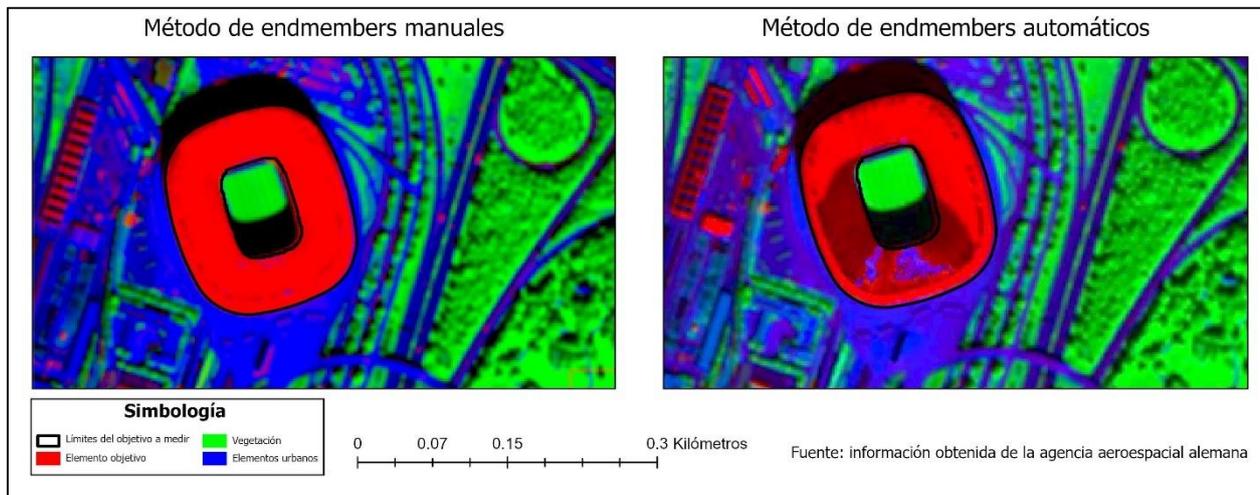


Figura 8: Clasificación en primera área de estudio: Hypspx

Fuente: Elaboración propia.

Pasando a los sensores satelitales, se puede observar las librerías espectrales utilizadas con EnMAP (figura 9). En este caso, la selección de firmas espectrales fue más sencilla, debido a que por su menor resolución espacial, la heterogeneidad de los elementos presentes es menor, aunque la mezcla de coberturas en el píxel reduce inevitablemente la precisión de los resultados finales. En este caso se han extraído cuatro firmas para los píxeles puros manuales y cinco para los automáticos.

En los píxeles puros automáticos, las firmas espectrales muestran un rango más amplio de valores de reflectancia. Por ejemplo, la curva del estadio y el asfalto tienen valores más altos de reflectancia, lo que puede indicar que el proceso automático está captando variaciones más finas o mezclas de materiales que el análisis manual no consideró. Los píxeles puros manuales

parecen más suavizados y con menos variabilidad en los valores de reflectancia. Esto podría deberse a que la selección manual de píxeles puros a menudo se enfoca en representar categorías más generales y no captura la misma riqueza de variaciones espectrales. Sin embargo, en desmezclado espectral es mejor obtener firmas más representativas y con mayor distancia espectral, especialmente cuando la mayoría de píxeles están mezclados.

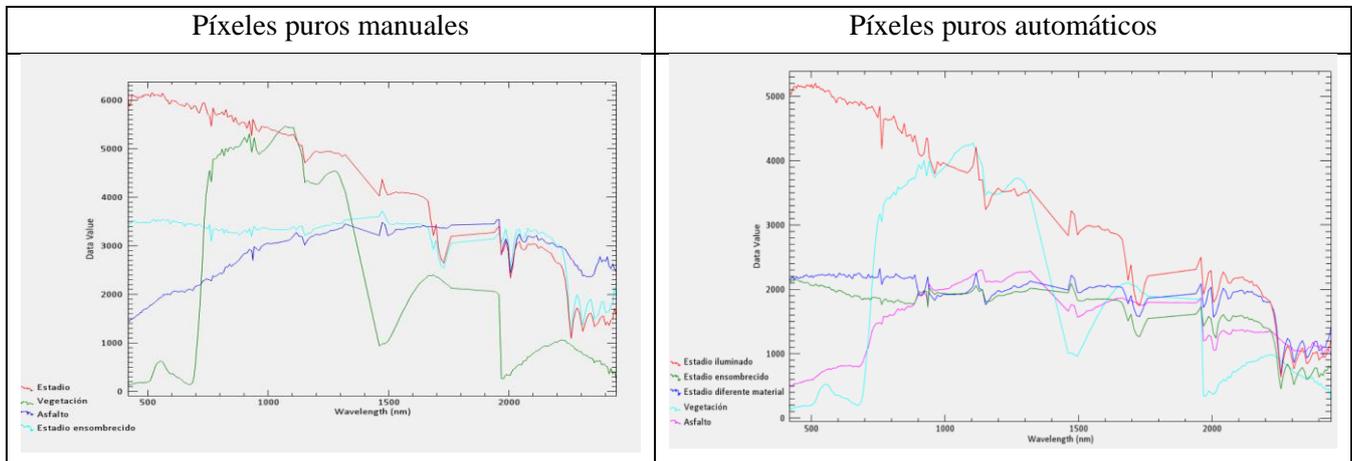


Figura 9: Librería espectral de los *endmembers* utilizados para elaboración del mapa de abundancia (primera área de estudio): EnMAP

Fuente: Elaboración propia.

La figura 10 muestra el resultado con EnMAP reclasificado en las tres categorías de interés al igual que se realizó para Hypspec. En este caso la vegetación como el asfalto parece representarse de un modo más fiel a la realidad, al igual que el estadio, donde el anillo exterior e inferior parecen mucho mejor delimitados. Entrando en diferenciar ambos criterios, se observa como la selección manual tiende a la simplificación, ya que, al haber un objetivo claro de clasificar un objetivo, se generalizan las firmas espectrales, agrupando variaciones menores dentro de una misma categoría.

Esta estrategia puede ser útil cuando el objetivo es una interpretación más rápida o general del área, como distinguir entre vegetación y superficies artificiales, o distinguir un elemento del resto, como es en este caso. Además, al evitar la detección de pequeñas variaciones espectrales dentro de cada material, se reduce el "ruido" en la clasificación, lo que mejora la percepción visual de una imagen más "limpia" o estructurada.

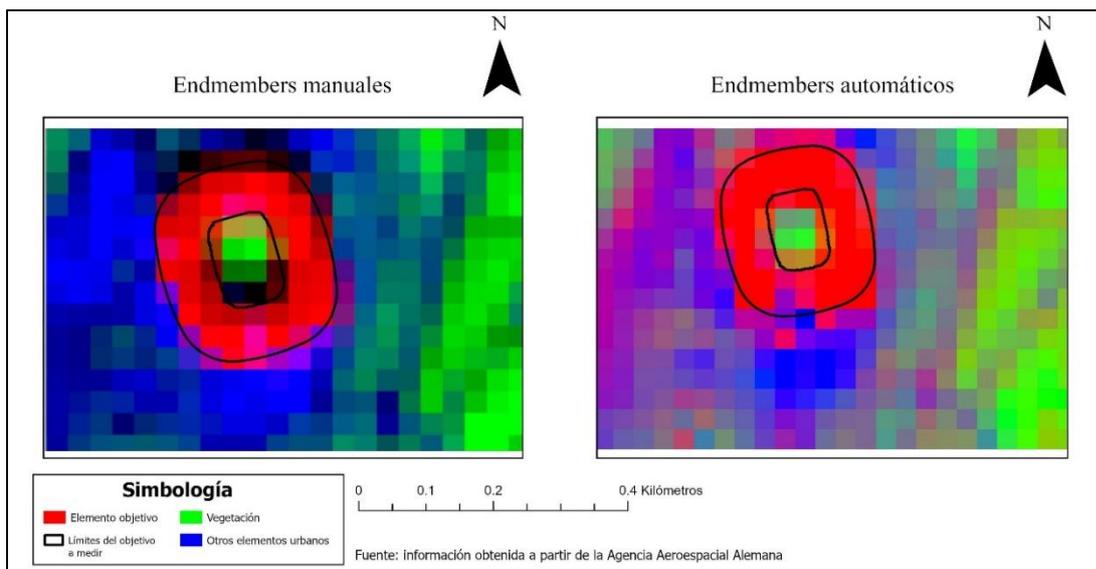


Figura 10: Clasificación en primera área de estudio: EnMAP.
Fuente: Elaboración propia.

En la figura 11 se pueden observar las firmas espectrales obtenidas con el sensor DESIS, en las que son evidentes las diferencias en la representación de los materiales. Los píxeles puros manuales muestran más detalles y fluctuaciones espectrales, capturando variaciones más finas, como las pequeñas diferencias en el comportamiento espectral del estadio iluminado, el asfalto y las superficies de vegetación. En cambio, los píxeles puros automáticos tienden a suavizar estas transiciones, proporcionando una representación más general y homogénea de los materiales. Esto es evidente en la vegetación y las áreas en sombra, donde los píxeles puros automáticos son más uniformes, mientras que los manuales presentan mayores variaciones. Aunque los píxeles puros automáticos capturan las firmas más representativas y reducen el ruido, pierden algunos detalles importantes en materiales como en la parte del estadio con material diferente, donde las curvas manuales muestran más variabilidad en el infrarrojo cercano, reflejando mayor sensibilidad a las diferencias espectrales internas de estos materiales.

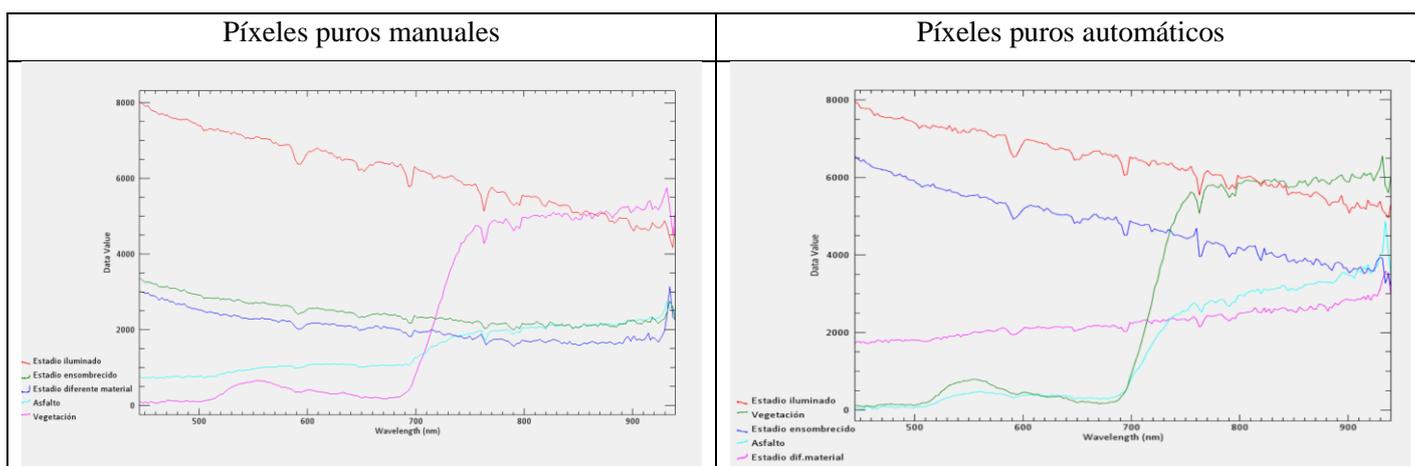


Figura 11: Librería espectral de los *endmembers* utilizados para elaboración del mapa de abundancia (primera área de estudio): DESIS

Fuente: Elaboración propia

Así, en la figura 12 se puede observar el resultado del desmezclado espectral con las firmas espectrales de DESIS. El método manual parece delimitar mejor el estadio, pero sin

embargo tiene importantes problemas en la delimitación de su anillo interior, al igual que infrarepresenta la vegetación. El método automático parece representar mejor la vegetación, pero a su vez sobrerrepresenta los materiales del estadio, denotándose mezcla con elementos con los que hay una separabilidad espectral marcada, como la vegetación.

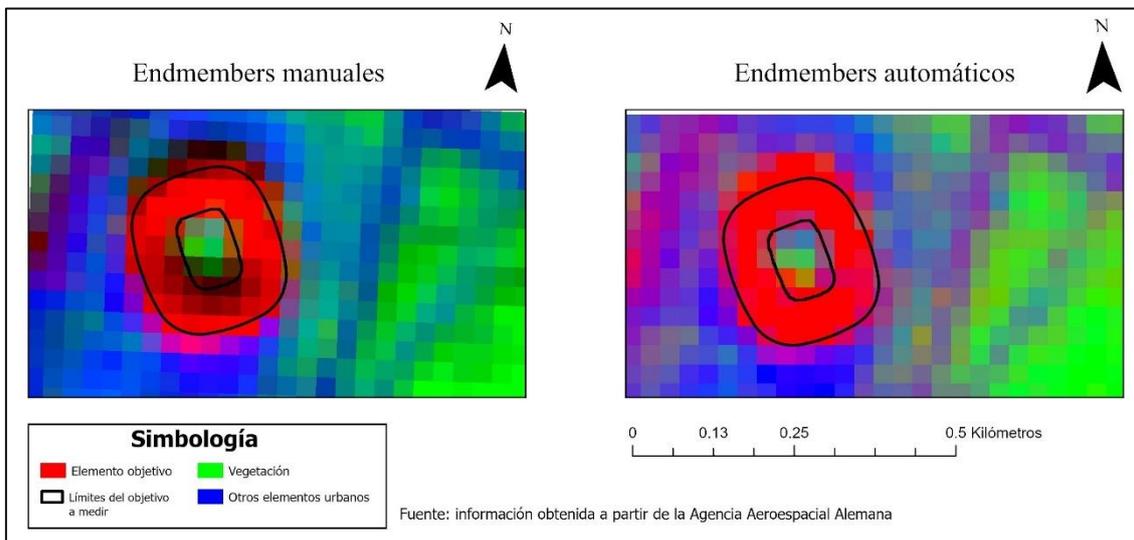


Figura 12: Clasificación en primera área de estudio: DESIS.

Fuente: Elaboración propia

La tabla 3 compara el error relativo porcentual y estimación de áreas de diferentes sensores hiperespectrales (HySpex, EnMAP y DESIS) utilizando métodos de extracción de píxeles puros manuales y automáticos. Los resultados muestran que el método manual de HySpex es el más preciso, con una subestimación mínima del área real (-0.78%), mientras que su versión automática presenta una mayor imprecisión (-8%). EnMAP, en ambos métodos, tiende a sobreestimar significativamente el área, especialmente con el método automático (+48%), lo que refleja la influencia de su menor resolución espacial.

En contraste, DESIS manual es altamente preciso (+1.5%), siendo más confiable que su versión automática, que sobreestima el área en un +26%, mostrando la potencialidad de su resolución espectral. En general, los métodos manuales resultan más precisos, capturando detalles finos sin sobreestimar, mientras que los métodos automáticos ofrecen mayor variabilidad espectral, pero tienden a perder precisión en la estimación del área.

Tabla 3: Precisión de los sensores en la primera zona de estudio.

Fuente: Elaboración propia

Sensor	N.º de firmas espectrales para medir el objetivo	Area (m2) Verdad terreno: 41528 m2	Error relativo porcentual
Hypex (manual)	3/7	41237.304	- 0.78 %
Hypex (automático)	4/7	38205.76	- 8 %
EnMAP (manual)	2/4	45265.52	+ 9 %
EnMAP (automático)	3/5	61461.44	+ 48 %
DESI (manual)	3/5	42150.92	+ 1,5 %
DESI (automático)	3/5	52532.85	+ 26 %

3.2 Segunda zona de estudio

En la segunda zona de estudio la complejidad aumenta, ya que en este caso no se está midiendo un solo objetivo de grandes dimensiones, sino varios de pequeñas dimensiones, lo que lo hace potencialmente difícil en escenarios donde la mezcla de coberturas es alta. En el caso de Hypspx, se pueden observar las firmas tomadas en la figura 13. El método manual se precedió de un Pixel Purity Index, siendo muy importante en este caso debido a que había mucha variabilidad en los materiales de construcción presente en los edificios de la zona. A nivel general, el método manual parece incluir en este caso una menor cantidad de materiales, ya que han sido cuidadosamente elegidos los necesarios para el objetivo a medir. Mientras tanto el método automático capta muchas de las firmas espectrales presentes en el manual, pero añadiendo algunas que tienen menor separabilidad espectral. La selección de píxeles puros tan parecidos puede provocar abundancias erróneas entre píxeles puros que están relacionados, complejizando la interpretación de resultados.

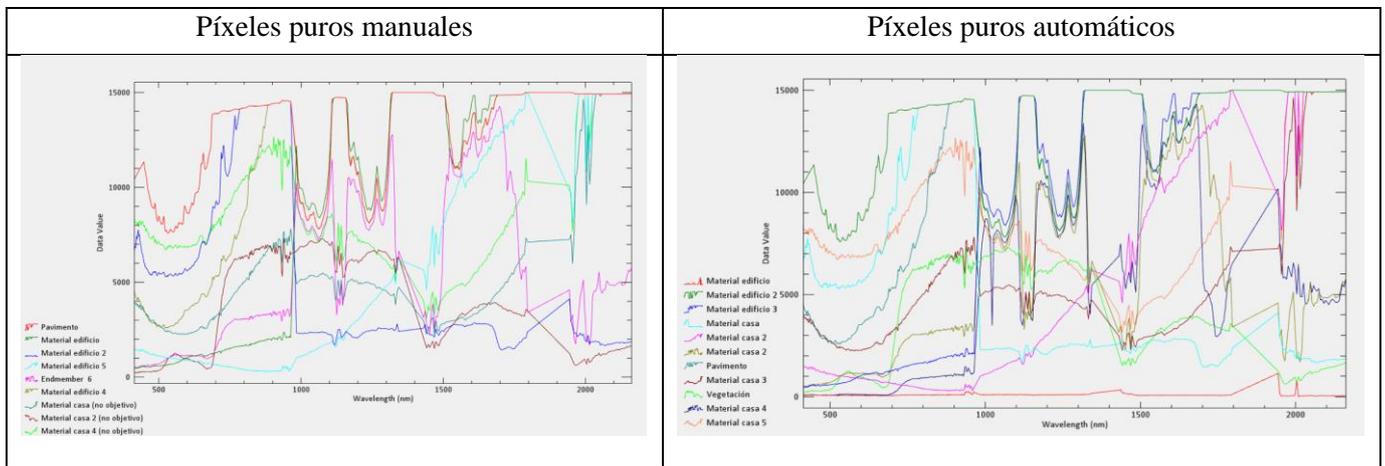


Figura 13: Librería espectral de los *endmembers* utilizados para elaboración del mapa de abundancia (segunda área de estudio): Hypspx.

Fuente: Elaboración propia

La figura 14 muestra los resultados del mapa de abundancia con Hypspx. Como se puede observar, los edificios se hallan mejor representados en el píxel puro de la izquierda. Esto se puede deber al gran número de píxeles puros en la derecha, que ha podido provocar un sobreajuste. Hay muchos falsos positivos más allá de los edificios a medir, debido a que en los materiales antrópicos son difíciles de identificar, especialmente cuando se dan ángulos de iluminación y perspectivas diferentes.

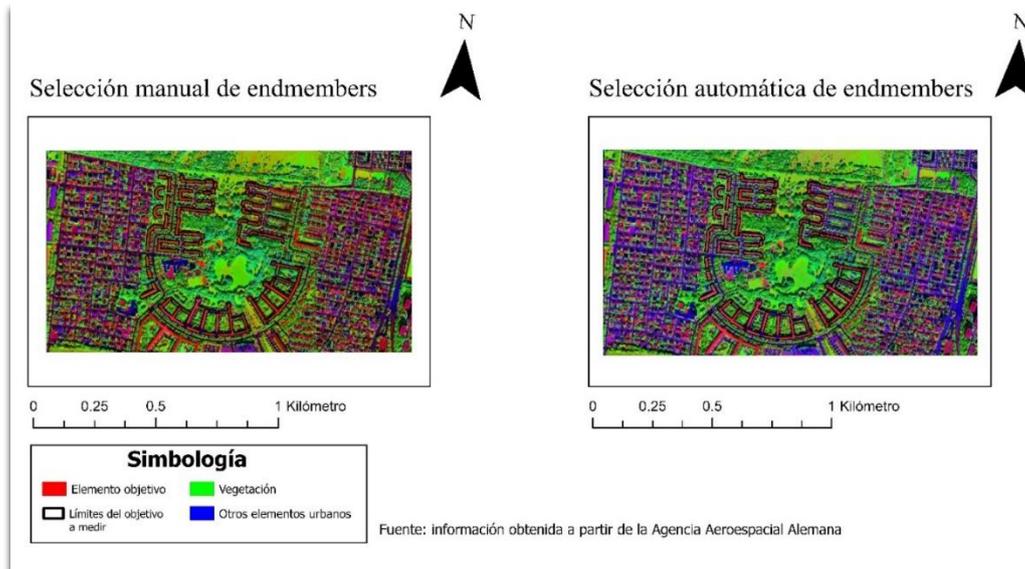


Figura 14: Clasificación en segunda área de estudio: Hypspx
Fuente: Elaboración propia.

Sin embargo, el uso de múltiples firmas espectrales con Hypspx, se reduce en buena medida con EnMAP, (figura 15) cuyas firmas espectrales se reducen solo a tres. En este caso, debido a la gran mezcla de coberturas, SMACC daba resultados muy malos, ya que no encontraba un píxel puro especialmente bueno para llevar a cabo el análisis. El reducido número de firmas espectrales busca intentar aprovechar la alta separabilidad espectral de las tres cubiertas para que el desmezclado espectral pueda tener un mejor rendimiento. Especialmente en este caso, donde no hay un píxel puro como tal, debido al tamaño de celdilla y a la relación objeto-píxel, resulta de interés generar estas firmas espectrales a partir de Regiones de Interés, lo que permite obtener una media de los valores de las celdillas elegidas. Sin embargo, esto reduciría en este caso la precisión de la medición, ya que aún así no se ha podido utilizar una firma espectral pura.

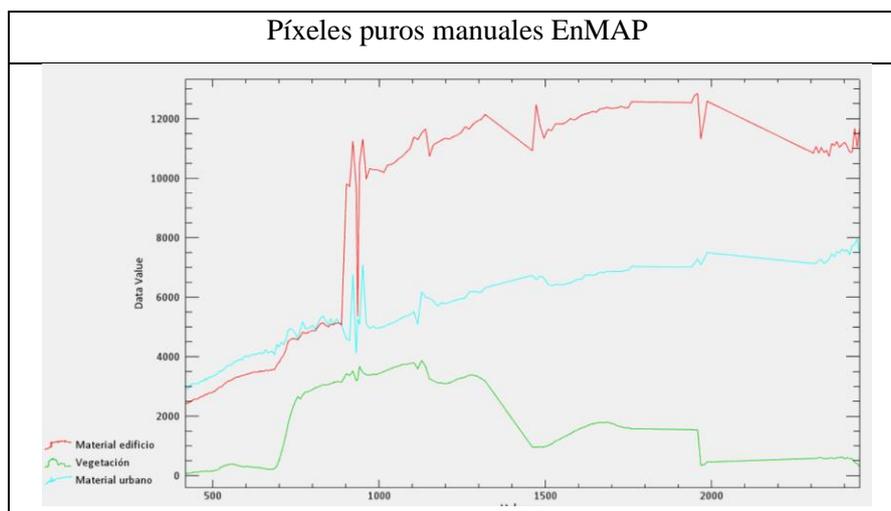


Figura 15: Librería espectral de los *endmembers* utilizados para elaboración del mapa de abundancia (segunda área de estudio): EnMAP
Fuente: Elaboración propia

Los resultados del mapa de la clasificación (figura 17) indican que el sensor EnMAP tiene verdaderas dificultades para captar elementos tan pequeños. Aun así, parte de las áreas rojizas indican la presencia de los edificios objetivo, pero tiene serios problemas con los falsos positivos de casas aledañas. La vegetación se halla bien representada, como en el caso anterior. Respecto

al último sensor, DESIS, ocurre lo mismo con sus firmas espectrales (figura 16), aunque sin embargo sus resultados en el mapa de clasificación (figura 17) resultan mucho más convincentes que con EnMAP. DESIS, a diferencia de EnMAP parece tener problemas en la representación de la vegetación, generalmente subestimando su extensión.

La subestimación de la vegetación por parte de DESIS en comparación con EnMAP es probablemente el resultado de la menor cobertura espectral del primero, especialmente en las bandas del infrarrojo de onda corta (SWIR), que son cruciales para la caracterización detallada de la vegetación.

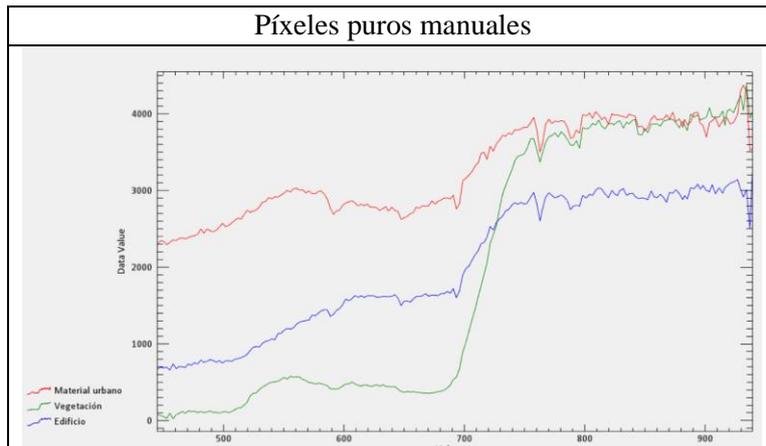


Figura 16: Librería espectral de los *endmembers* utilizados para elaboración del mapa de abundancia (segunda área de estudio): DESIS. Fuente: Elaboración propia

Aunque DESIS parece representar mejor las áreas urbanas, debido a que está diseñado para capturar datos en un rango espectral más enfocado (400-1000 nm), cubriendo el espectro visible e infrarrojo cercano (NIR) con 235 bandas. Esto le permite captar detalles finos en la reflectancia de materiales urbanos, como el asfalto, techos y vidrio, que tienen variaciones espectrales más notorias en el visible y NIR. EnMAP, en cambio, tiene una cobertura espectral mucho más amplia (420-2450 nm), que incluye el infrarrojo de onda corta (SWIR), ideal para caracterizar vegetación, minerales y suelos, pero que puede agregar complejidad en el análisis de zonas urbanas, donde el detalle espectral adicional puede no ser tan necesario o incluso generar más ruido en los materiales urbanos.

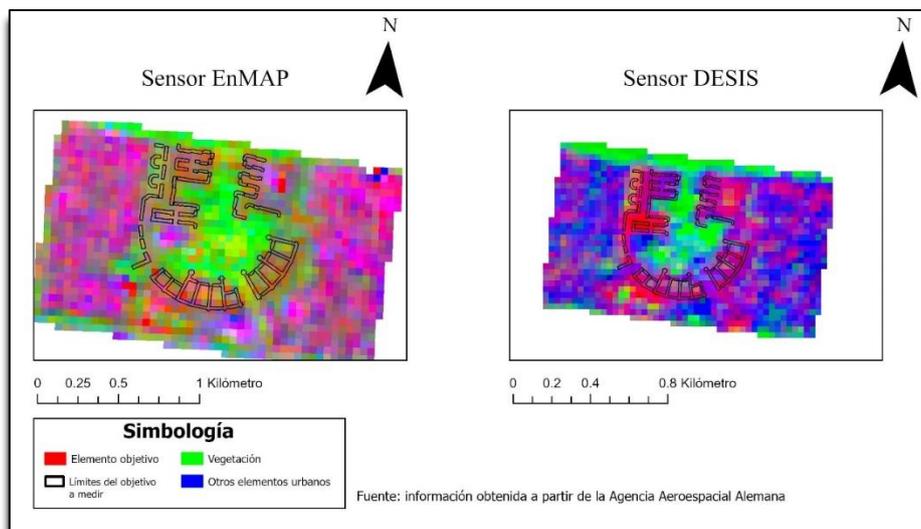


Figura 17: Clasificación en segunda área de estudio: EnMAP

Fuente: Elaboración propia

Los últimos resultados relativos al área de la segunda zona de estudio se pueden observar en la tabla 4. Por un lado, todos los sensores bajan en su precisión respecto a la primera zona, aspecto comprensible debido al tamaño y número de objetos a medir. Así, el resultado de principal interés radica en el mal desempeño de EnMAP, y en el buen desempeño de DESIS, superando a Hypspx. Este hecho confirma como DESIS a pesar de llevar el mismo sensor en el NIR que EnMAP, al poseer una mejor resolución espectral, puede distinguir más fácilmente los materiales presentes en zonas de mayor mezcla de coberturas.

Tabla 4: Precisión de los sensores en la segunda zona de estudio

Fuente: Elaboración propia

Sensor	N.º de firmas espectrales para medir el objetivo	Area (m2) Verdad terreno: 64323 m2	Error relativo porcentual
Hypspx (manual)	4/9	55961	- 13 %
Hypspx (automático)	3/11	46955.79	- 33 %
EnMAP (manual)	1/3	28302.12	- 66 %
DESI (manual)	1/3	68825.61	+ 7 %

Otro aspecto que llama la atención son las firmas espectrales utilizadas. DESIS con una sola firma ha sido capaz de aproximarse más que Hypspx a la medida real. Este aspecto indica la idealidad de este sensor para tomar medidas en análisis rápidos, especialmente en áreas urbanas. La mayor resolución espacial de un sensor es beneficioso en muchos aspectos, pero también trae complejidades al análisis como aquí se demuestra.

4. Discusión

Los resultados evidencian que el sensor HySpex, con su alta resolución espacial (1 metro), es el más preciso para la medición de superficies urbanas, especialmente cuando se utiliza la extracción manual de píxeles puros. Esto es consistente con lo esperado, ya que su resolución espacial permite una mayor diferenciación de coberturas y reduce la mezcla de firmas espectrales en un mismo píxel. Sin embargo, la alta dimensionalidad espectral de HySpex también introduce desafíos en cuanto a la complejidad del análisis, lo que se refleja en la necesidad de aplicar filtros de paso bajo para mitigar el efecto del ruido espectral, más intenso en zonas urbanas. Al igual que su obtención se basa en campañas de vuelo, por lo que, a pesar de su calidad de los datos, es un método más caro y sin cobertura repetitiva del territorio.

Esta complejidad se hizo evidente en las áreas con sombra o con superficies altamente reflectantes, donde el ruido espectral afectó negativamente la calidad de los resultados. Arnaud Le Bris (2019) en su estudio sobre sensibilidad de clasificación de materiales urbanos menciona la enorme importancia que juega la resolución espacial en la identificación de edificios pequeños. Mientras que elementos grandes, como el estadio analizado, conserva píxeles puros en resoluciones espaciales más bajas (como treinta metros), los elementos pequeños (segunda zona de estudio), tienen ya problemas en su identificación a partir de los ocho metros de tamaño de píxel (Le Bris & Chehata, 2019). Este hecho está directamente relacionado con la unidad mínima cartografiada, hallándose los elementos de la segunda área de estudio por debajo de dicho límite en los sensores EnMAP y DESIS. Aunque, no se pueda cartografiar su forma, como se observa en los mapas de clasificación, si es posible aproximar la proporción del objetivo en los diferentes píxeles presentes, como indica el resultado de DESIS.

En la primera área de estudio queda constatando la capacidad de tanto EnMAP como DESIS de detectar objetos grandes de una manera precisa. Sin embargo, DESIS consiguió resultados más

precisos, más próximos a los de Hypspx. Esta diferencia aumenta en la segunda área de estudio, donde las imágenes de EnMAP infraestima en buena manera la dimensión de los elementos a medir, mientras que las de DESIS los sobreestiman levemente, aunque se halló más cerca en términos de error relativo que Hypspx.

El mejor rendimiento de DESIS frente a EnMAP puede responder a factores de diferente naturaleza. Por un lado, el reciente lanzamiento de EnMAP implica que muchas de sus imágenes no están del todo pulidas en aspectos técnicos, implicando la aplicación de una corrección geométrica o atmosférica todavía en desarrollo. Por otro lado, las condiciones de adquisición de las imágenes de ambos sensores también pueden haber provocado una leve diferencia en la precisión de los resultados.

Sin embargo, el sensor del SWIR de EnMAP podría haber sido el factor de mayor influencia en estos resultados. Como se mencionó anteriormente, el cociente señal-ruido de EnMAP en dicha área del espectro no es muy alto en comparación con el VNIR. Esto puede haber causado un aumento del ruido en la imagen, dificultando la distinción de elementos urbanos espectralmente próximos. El SWIR es de elevado interés en áreas urbanas ya que muchos materiales similares se pueden distinguir mediante bandas de absorción en esta región (Jilge et al., 2019). Aunque este último factor se relega a una hipótesis, que requiere un análisis independiente para contrastar su validez. Sería de interés para mejorar los resultados aplicar alguna técnica que reduzca el ruido de la imagen, ya sea por métodos más complejos como la aproximación de tensores de bajo rango (Zhang et al., 2020) o autoencoders para descomposición espectral (Zhang et al., 2020) o por métodos más sencillos como la reducción de dimensionalidad de la imagen, como a través de la técnica de componentes principales.

Otro aspecto que podría mejorar los resultados de EnMAP sería variar el criterio en la obtención de firmas espectrales. En el artículo escrito por Wieke Heldens et al. (2011), se teoriza sobre los problemas de EnMAP a investigar en su lanzamiento (gracias en buena manera a la experiencia con Hyperion), mencionando la posible dificultad de dicho sensor en la elaboración de técnicas de desmezclado espectrales en áreas urbanas. Una de las soluciones sugeridas radica en obtener los *endmembers* de una librería espectral, permitiendo obtener una mejor referencia frente a la selección de píxeles puros en contextos de una intensiva mezcla de coberturas.

Aunque al disponer de la imagen de Hypspx, es posible obtener sus *endmembers* y remuestrearlos para ser usados en EnMAP. Esto abre la posibilidad de aplicación de técnicas de fusión de datos. Dicha técnica busca combinar información de diferentes sensores, para lograr resultados no posibles de obtener mediante un solo sensor. Pese a la simpleza de su definición, esta técnica es de suma complejidad debido a que el alineamiento de datos resulta una tarea difícil (Lahat et al., 2015). Por ejemplo, la combinación de EnMAP y DESIS podría proporcionar una mejor resolución temporal, además de resultados mejor contrastados. Sin embargo, su diferente ángulo de observación, precisión geométrica o sensible diferencia en resolución radiométrica requiere un importante trabajo en intentar compatibilizar ambas imágenes. Sin embargo, la aplicación del remuestreo de los *endmembers* de Hypspx a EnMAP no es una tarea tan compleja, ya que las firmas espectrales serían elementos extraídos de la imagen, lo que se conoce como una fusión tardía o *decisión-based fusion* (Bayouh, 2024). Esta técnica ya fue aplicada entre Hypspx y DESIS en el artículo de Danielle Cerrá (2022), dando resultados muy buenos en la detección de paneles solares, donde DESIS llegó a un porcentaje de error muy similar a Hypspx. Por lo que sería interesante en futuros trabajos analizar que tal funciona esta técnica en EnMAP, ya que a diferencia de DESIS, no es necesario eliminar el espectro del SWIR para el remuestreo.

Estas técnicas se relegan meramente a los aspectos espectrales, pero otra opción radica en mejorar la resolución espacial, a través de la técnica de *pansharpening*. Esta se basa en la mejora de la resolución espacial de una imagen multispectral e hiperespectral utilizando una imagen

pancromática. Hay multitud de algoritmos como muestra el artículo escrito por Gemine et al (2015), aunque aplicados fundamentalmente a imágenes multiespectrales. La aplicación de esta técnica a imágenes hiperespectrales es un asunto aún discutido, ya que su alta resolución espectral dificulta la aplicación de algoritmos y sus buenos resultados, especialmente en contextos urbanos. Podría resultar interesante intentar mejorar la resolución espacial de la imagen de EnMAP, sin embargo, no existe apenas literatura científica que haya tratado dicha cuestión (Loncan et al., 2015).

Por último, se propone un nuevo método de validación para contrastar la validez de los mapas de clasificación. Este método de validación se basa en generar un mapa de abundancia (figura 18) a partir del vector que se posee el elemento a medir, del cual se ha extraído el área anterior. Se realizaría a través de rasterizar el estadio en una resolución detallada (0.5 x 0.5 en este caso) y extraer mediante unas estadísticas zonales, la suma de píxeles que caen en cada zona de la malla 30x30. El resultado se divide por el área total, obteniendo así un mapa de abundancia lo más próximo a la realidad posible. Así se podría observar que píxeles del estadio están sobremedidos y cuales inframedidos, permitiendo una mejor aproximación y corrección de errores.

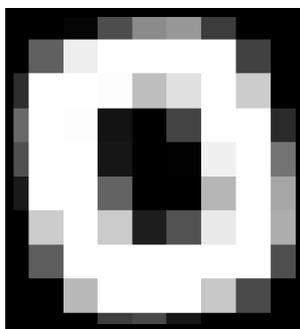


Figura 18: método de validación propuesto: mapa de abundancia como verdad de campo en la primera zona de estudio.

Fuente: elaboración propia.

5. Conclusiones

La investigación desarrollada a lo largo de este trabajo ha permitido analizar la eficacia de los sensores hiperespectrales HySpex, EnMAP y DESIS en la estimación de superficies en áreas urbanas. Se ha evidenciado que, aunque HySpex presenta la mayor precisión en la detección de superficies debido a su alta resolución espacial, el sensor DESIS ha mostrado un buen rendimiento en la medición de áreas más complejas como las urbanas, gracias a su resolución espectral y espacial equilibrada. Aún es necesario que se realicen más estudios sobre la potencialidad de EnMAP, especialmente frente a su predecesor DESIS, para conocer las posibles mejores a aplicar.

Uno de los puntos clave es la selección y uso de firmas espectrales puras. El método manual, aunque laborioso, ha proporcionado una mayor precisión en la identificación de los píxeles más representativos en áreas urbanas complejas. Mientras que los métodos automáticos, aunque útiles, presentan mayor variabilidad en contextos de alta mezcla espectral, lo que puede complicar la interpretación de los resultados. Sin embargo, queda aplicar esta metodología en otros contextos, para poder contrastar lo analizado en este documento, en especial con relación a EnMAP.

Existen diferentes metodologías que permitirían mejorar la calidad de tanto los datos como de los resultados, por lo que se pueden abrir nuevas perspectivas en este trabajo. Por lo general EnMAP todavía es un satélite relativamente inexplorado, y desafortunadamente DESIS dejará de ofrecer imágenes en un futuro, por lo que este trabajo proporciona un marco de comparación entre los sensores que nos permite evaluar las capacidades de los nuevos sensores. En este sentido, es

interesante aprovechar su reducido archivo temporal compartido para analizar las diferencias entre ambos sensores.

6. Referencias bibliográficas

Aggarwal, A., & Garg, R. D. (2015). Systematic approach towards extracting endmember spectra from hyperspectral image using PPI and SMACC and its evaluation using spectral library. *Applied Geomatics*, 7(1), 37–48. <https://doi.org/10.1007/s12518-014-0149-5>

Akbari, D., & Rokni, K. (2022). Spectral-spatial classification of hyperspectral images based on non-linear principal component analysis and deep learning models. *International Journal of Remote Sensing*, 43(17), 6561–6580. <https://doi.org/10.1080/01431161.2022.2142079>

Bayouhd, K. (2024). A survey of multimodal hybrid deep learning for computer vision: Architectures, applications, trends, and challenges. *Information Fusion*, 105, 102217. <https://doi.org/10.1016/j.inffus.2023.102217>

Ceamanos, X., & Valero, S. (2016). Processing hyperspectral images. In *Optical Remote Sensing of Land Surface: Techniques and Methods* (pp. 163–200). <https://doi.org/10.1016/B978-1-78548-102-4.50004-1>

Cerra, D., Ji, C., & Heiden, U. (2022). Solar panels area estimation using the spaceborne imaging spectrometer DESIS: Outperforming multispectral sensors. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, V-1, 9–14. Copernicus Publications.

Chang, C.-I., & Plaza, A. (2006). A fast iterative algorithm for implementation of pixel purity index. *IEEE Geoscience and Remote Sensing Letters*, 3(1), 63–67. <https://doi.org/10.1109/LGRS.2005.856701>

Chuvieco, E., & Congalton, R. G. (1988). Mapping and inventory of forest fires from digital processing of TM data. *Geocarto International*, 3(4), 41–53.

Chuvieco, E., Aguado, I., & Yebra, M. (2010). Estimation of live fuel moisture content from MODIS images for fire risk assessment. *Agricultural and Forest Meteorology*, 150(7–8), 861–870.

DLR Remote Sensing Technology Institute (IMF). (2016). Airborne Imaging Spectrometer HySpex. *Journal of Large-Scale Research Facilities*, 2, A93. <http://dx.doi.org/10.17815/jlsrf-2-151>

Goetz, A. F. H., Vane, G., Solomon, J. E., & Rock, B. N. (1985). Imaging spectrometry for Earth remote sensing. *Science*, 228(4704), 1147–1153. <https://doi.org/10.1126/science.228.4704.1147>

Ferrato, L.-J., & Forsythe, K. (2013). Comparing hyperspectral and multispectral imagery for land classification of the Lower Don River, Toronto. *Journal of Geography and Geology*, 5(1), 92. <https://doi.org/10.5539/jgg.v5n1p92>

Foerster, S., Guanter, L., Lopez, T., Moreno, J., Rast, M., & Schaepman, M. E. (2019). Guest Editorial: International Space Science Institute (ISSI) Workshop on Space-Borne Imaging Spectroscopy for Exploring the Earth's Ecosystems. *Surveys in Geophysics*.

- García-Pintado, J., Martínez-Llario, J. C., & Martínez-Garrido, M. I. (2009). Satellite remote sensing for monitoring water quality and hydrological variables in flooded areas: The case of the Guadalquivir River. *Hydrological Processes*, 23(11), 1601–1614.
- Heiden, U. (2007). Urban structure type characterization using hyperspectral remote sensing and height information. *Photogrammetric Engineering & Remote Sensing*, 73(4), 503–511.
- Heldens, W., Heiden, U., Esch, T., Stein, E., & Müller, A. (2011). Can the future EnMAP mission contribute to urban applications? A literature survey. *Remote Sensing*, 3(9), 1817–1846. <https://doi.org/10.3390/rs3091817>
- Ilehag, R., Schenk, A., Huang, Y., & Hinz, S. (2019). KLUM: An urban VNIR and SWIR spectral library consisting of building materials. *Remote Sensing*, 11(18), 2149. <https://doi.org/10.3390/rs11182149>
- Jilge, M., Heiden, U., Neumann, C., & Feilhauer, H. (2019). Gradients in urban material composition: A new concept to map cities with spaceborne imaging spectroscopy data. *Remote Sensing of Environment*, 223, 179–193.
- Lahat, D., Adali, T., & Jutten, C. (2015). Multimodal data fusion: An overview of methods, challenges, and prospects. *Proceedings of the IEEE*, 103(9), 1449–1477. <https://doi.org/10.1109/JPROC.2015.2460697>
- Le Bris, A., & Chehata, N. (2019). Sensitivity of urban material classification to spatial and spectral configurations from visible to short-wave infrared. *2019 Joint Urban Remote Sensing Event (JURSE)*, 1–4. <https://doi.org/10.1109/JURSE.2019.8809029>
- Loncan, L., de Almeida, L. B., Bioucas-Dias, J. M., Briottet, X., Chanussot, J., Dobigeon, N., Fabre, S., Liao, W., Licciardi, G. A., Simões, M., Tourneret, J.-Y., Veganzones, M. A., Vivone, G., Wei, Q., & Yokoya, N. (2015). Hyperspectral pansharpening: A review. *IEEE Geoscience and Remote Sensing Magazine*, 3(3), 27–46.
- Li, D., & Chen, Y. (Eds.). (2012). *Advanced remote sensing: Terrestrial information extraction and applications*. Academic Press.
- Martín Isabel, M. P., García Alonso, M., & Martínez Vega, F. J. (2010). Avances en teledetección: instrumentos y aplicaciones. *Ciudad y Territorio Estudios Territoriales*, 42(165–166), 551–564. <https://doi.org/10.2134/recyt.v42n165-6p551-564>
- Martínez, S., & Gilabert, M. A. (2009). Vegetation dynamics from NDVI time series analysis using the wavelet transform. *Remote Sensing of Environment*, 113(9), 1823–1842.
- Müller, R., Alonso, K., Krawczyk, H., Bachmann, M., Cerra, D., Krutz, D., Dietrich, D., Gerasch, B., Ziel, V., Heiden, U., & de los Reyes, R. (2018). Overview and status of the DESIS mission. *Whispers 2018, Amsterdam, Netherlands*.
- Myint, S. W., Mesev, V., Quattrochi, D. A., & Wentz, E. A. (2015). Urban image classification: Per-pixel classifiers, subpixel analysis, object-based image analysis, and geospatial methods. In *Remotely Sensed Data Characterization, Classification, and Accuracies* (Vol. 1, pp. 219–230). CRC Press. <https://doi.org/10.1201/b19294>
- National Research Council. (1998). *People and pixels: Linking remote sensing and social science*. Washington, DC: The National Academies Press. <https://doi.org/10.17226/5963>

- Ozcan, A., Leloglu, U., & Süzen, M. (2023). Prediction of plant pigments for phytosanitary and yield estimation. In *Plant Phytosanitary and Yield Prediction*, 10–23. <https://doi.org/10.1016/B978-0-323-91068-2.00002-3>
- Pettorelli, N., Vik, J. O., Mysterud, A., Gaillard, J. M., Tucker, C. J., & Stenseth, N. C. (2005). Using the satellite-derived NDVI to assess ecological responses to environmental change. *Trends in Ecology & Evolution*, 20(9), 503–510.
- Sánchez-Hernández, C., Batlles, F. J., & Bosch, J. L. (2007). Assessment of land-use seasonal evolution using Landsat TM and NOAA AVHRR satellite data in a semi-arid area in SE Spain. *International Journal of Remote Sensing*, 28(16), 3583–3595.
- Storch, T., & Müller, R. (2017). Processing chains for DESIS and EnMAP imaging spectroscopy data: Similarities and differences. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-3/W3, 177–180. <https://doi.org/10.5194/isprs-archives-XLII-3-W3-177-2017>
- Wang, H., Cheng, Y., Liu, N., Zhao, Y., Chan, J. C., & Li, Z. (2022). An illumination-invariant shadow-based scene matching navigation approach in low-altitude flight. *Remote Sensing*, 14(16), 3869. <https://doi.org/10.3390/rs14163869>
- West, J. S., Bravo, C., Oberti, R., Lemaire, D., Moshou, D., & McCartney, H. A. (2003). The potential of optical canopy measurement for targeted control of field crop diseases. *Annual Review of Phytopathology*, 41, 593–614. <https://doi.org/10.1146/annurev.phyto.41.121702.103726>
- Van der Meer, F. D. (2012). Remote sensing and spectral geology. *Treatise on Geochemistry*, 7(1), 11–30.
- Vivone, G., Alparone, L., Chanussot, J., Garzelli, A., & Licciardi, G. A. (2015). A critical comparison among pansharpening algorithms. *IEEE Transactions on Geoscience and Remote Sensing*, 53(5), 2565–2586.
- Wulder, M. A., Masek, J. G., Cohen, W. B., Loveland, T. R., & Woodcock, C. E. (2012). Opening the archive: How free data has enabled the science and monitoring promise of Landsat. *Remote Sensing of Environment*, 122, 2–10. <https://doi.org/10.1016/j.rse.2012.01.010>
- Zarco-Tejada, P. J., Miller, J. R., Mohammed, G. H., Noland, T. L., & Sampson, P. H. (2002). Vegetation stress detection through chlorophyll a+b estimation and fluorescence effects on hyperspectral imagery. *Journal of Environmental Quality*, 31(5), 1433–1441. <https://doi.org/10.2134/jeq2002.1433>
- Zhang, C., Zhou, L., Zhao, Y., Zhu, S., Liu, F., & He, Y. (2020). Noise reduction in the spectral domain of hyperspectral images using denoising autoencoder methods. *Chemometrics and Intelligent Laboratory Systems*, 203, 104063. <https://doi.org/10.1016/J.CHEMOLAB.2020.104063>
- Zhang, H., Liu, L., He, W., & Zhang, L. (2020). Hyperspectral image denoising with total variation regularization and nonlocal low-rank tensor decomposition. *IEEE Transactions on Geoscience and Remote Sensing*, 58(5), 3071–3084. <https://doi.org/10.1109/TGRS.2019.2947333>