

Universidad Pública de Navarra

Nafarroako Unibertsitate Publikoa

**ESCUELA TECNICA SUPERIOR
DE INGENIEROS AGRONOMOS**

***NEKAZARITZAKO INGENIARIEN
GOI MAILAKO ESKOLA TEKNIKOA***

**METODOLOGÍA PARA EL CÁLCULO DE LAS ALTITUDES DE LOS EDIFICIOS
EN ZONAS URBANAS MEDIANTE SUS SOMBRAS**

.....

presentado por

Irati Dorronsoro Aguirrezabal *(e)k*

aurkeztua

**MÁSTER EN SISTEMAS DE INFORMACIÓN GEOGRÁFICA Y TELEDETECCIÓN
*MASTERRA INFORMAZIO SISTEMA GEOGRAFIKOETAN ETA TELEDETEKZIOAN***

Septiembre, 2019 / 2019, *Iraila*



Resumen

Este Trabajo Fin de Máster tiene como objetivo aplicar una metodología para la obtención de las altitudes de los edificios en zonas urbanas a través de las sombras de estas, utilizando una pareja de imágenes multiespectral y pancromática captadas por el satélite francés Pleiades correspondientes a la ciudad de Melbourne (Australia). Con el objeto de generar una imagen multiespectral de muy alta resolución espacial, se ha aplicado un proceso de pansharpening a ambas imágenes. A partir de esta imagen, la extracción de las sombras y edificios se ha realizado mediante la aplicación de un clasificador supervisado que se ha seleccionado después de aplicar los algoritmos, KNN (k-nearest neighbor), SVM (Support Vector Machine) y Random Forest, y calcular sus fiabilidades globales y precisiones. Una vez identificados edificios y sombras, se han vectorizado los ficheros ráster, calculado los centroides de los edificios y definido la línea de acimut solar asociada a cada edificio, cuya intersección con la sombra correspondiente ha permitido determinar su longitud. A partir del dato de longitud de cada sombra y teniendo en cuenta el ángulo de elevación solar, se han calculado las altitudes de los edificios.

Palabras clave: sombras, edificios, altitud, KNN, SVM, Random Forest, elevación solar, acimut solar

Abstract

The aim of the project is applying a methodology to obtain the heights of buildings in an urban area using their shadows. To carry out the calculation, a panchromatic and multispectral satellite images obtained by the French satellite Pleiades from Melbourne (Australia) have been used. To obtain a very high spatial resolution multispectral image a pansharpening procedure has been applied. From this image, the extraction of the shadows and the buildings has been done applying KNN (k-nearest neighbor), SVM (Support Vector Machine) and Random Forest classification algorithms. By calculating the overall reliability and the precision of each one, the best classifier has been chosen to classify the image. The results of the classification have been vectorized and with it the centroids of the buildings have been detected. A copy of these have been displaced in the direction of the solar azimuth. The both point layers have been unified by lines and from the intersection with the shadows the length of the shadows haven been obtained. To finish with, relating the length of the shadows and the solar elevation with a trigonometric equation, the heights of the buildings have been calculated.

Keywords: shadows, buildings, height, KNN, SVM, Random Forest, solar elevation, solar azimuth



Laburpena

Lan honen helburua eraikinen itzalak erabiliz hauen garaiera kalkulatzeko metodologia bat aplikatzea da. Hau aurrera eramateko Pleiades satellite frantziarrak Melbourne (Australia) hiriarri eginiko irudi pankromatiko bat eta multiespektral bat erabili dira. Bereizmen espazial handiko irudi multiespektral bat lortzeko helburuarekin panhsarpening prozedura aplikatu da. Irudi honetatik abiatuz, itzalak eta eraikuntzak atera dira KNN (k-nearest neighbor), SVM (Support Vector Machine) eta Random Forest sailkapen gainbegiratuak aplikatuz. Hauen ebaluaketa egiteko fidagarritasun globala eta zehaztasuna kalkulatu dira eta hauen bidez sailkatzaile onena aukeratu da. Sailkapenen emaitza bektorizatu egin dira eta bertatik eraikuntzen zentroideak kalkulatu dira. Hauen kopia bat eguzki azimutaren norabidean mugitu da ondoren lerro batez bi geruzetako puntuak batuz. Lerro honen eta itzalen geruzaren intersekzioaren bidez posible izan da itzalen luzera kalkulatzea eta honen bidez eta eguzki garaieraren arteko erlazio trigonometrikoaren bidez eraikuntzen garaierak kalkulatu dira.

Hitz gakoak: itzalak, eraikinak, garaiera, KNN, SVM, Random Forest, eguzkiaren goratzea, eguzkiaren azimuta

Índice

1 – Introducción	15
2 – Objetivos	17
3 – Zona de estudio	19
4 – Material	21
4.1. Imágenes de partida.....	21
4.2. Software Monteverdi.....	22
5 – Métodos.....	25
5.1. Preprocesamiento de las imágenes: pansharpening o fusión de la multiespectral y pancromática	27
5.2. Extracción de sombras y edificios.....	29
5.3. Cálculo de la posición del sol en el momento de la adquisición de la imagen: ángulos cenital y acimutal del sol.....	35
5.4. Cálculo de las longitudes de las sombras	37
5.5. Cálculo de altitudes de los edificios	39
6 – Resultados y Discusión	41
6.1. Preprocesamiento de las imágenes: pansharpening o fusión de la multiespectral y pancromática	41
6.2. Extracción de sombras y edificios.....	42
6.3. Cálculo de la posición del sol en el momento de la adquisición de la imagen: ángulos cenital y acimutal del sol.....	47
6.4. Cálculo de las altitudes de los edificios	48
7 – Conclusiones	51
ANEXOS.....	55

Índice de Figuras

Figura 1: Representación de la zona de estudio	19
Figura 2: Imagen pancromática original adquirida con el satélite Pleiades	21
Figura 3: Imagen multiespectral original adquirida con el satélite Pleiades	22
Figura 4: Representación del esquema seguido en el trabajo.....	26
Figura 5: Representación del esquema de la transformada wavelet à trous.....	27
Figura 6: Esquema seguido en la aplicación de la transformada de wavelet à trous	29
Figura 7: Representación de los ángulos solares.....	37
Figura 8: Línea de unión entre el centroide de los edificios y su correspondiente en de la sombra	38
Figura 9: Relación trigonométrica entre la elevación solar, longitud de sombra y la altitud de un objeto	39
Figura 10: Imagen pansharpened obtenida a través de la metodología transformada wavelet à trous.....	41
Figura 11: Representación detallada de la combinación de la imagen pancromática y la multiespectral	41
Figura 12: Imagen de las sombras clasificadas	43
Figura 13: Representación detallada de la clasificación de las sombras.....	43
Figura 14: Imagen de la vegetación clasificada aplicando una máscara de sombras.....	45
Figura 15: Representación detallada de la clasificación de la vegetación	45
Figura 16: Imagen de los edificios clasificados aplicando una máscara de sombras y vegetación.....	47
Figura 17: Representación detallada de la clasificación de los edificios	47
Figura 18: Sombras vectorizadas y corregidas.....	48
Figura 19: Edificios vectorizados con sus correspondientes centroides	49
Figura 20: Grafico de la cantidad de edificios en cada rango de altitudes.....	50

Índice de Tablas

Tabla 1: Estadísticas y ponderación de cada banda	29
Tabla 2: Subconjuntos creados para cada uno de las clasificaciones.....	31
Tabla 3: Información de la iteración 1 de la clasificación orientada a la identificación de sombras.....	31
Tabla 4: Información de la iteración 2 de la clasificación orientada a la identificación de sombras.....	31
Tabla 5: Información de la iteración 3 de la clasificación orientada a la identificación de sombras.....	31
Tabla 6: Información de la iteración 1 de la clasificación orientada a la identificación de vegetación.....	31
Tabla 7: Información de la iteración 2 de la clasificación orientada a la identificación de vegetación.....	32
Tabla 8: Información de la iteración 3 de la clasificación orientada a la identificación de vegetación.....	32
Tabla 9: Información de la iteración 1 de la clasificación orientada a la identificación de los edificios	32
Tabla 10: Información de la iteración 2 de la clasificación orientada a la identificación de los edificios	32
Tabla 11: Información de la iteración 3 de la clasificación orientada a la identificación de los edificios	32
Tabla 12: Representación de una matriz de confusión.....	34
Tabla 13: Media de las fiabilidades globales y precisiones conseguidas para las sombras	42
Tabla 14: Media de las fiabilidades globales y precisiones conseguidas para las sombras	44
Tabla 15: Media de las fiabilidades globales y precisiones conseguidas para las sombras	46
Tabla 16: Ángulos solares dados por la cabecera de la imagen original.....	48
Tabla 17: Ejemplos de los resultados obtenidos para las longitudes de las sombras de los edificios	49

1 – Introducción

La teledetección es la ciencia que permite extraer información o detectar objetos de la superficie terrestre utilizando la radiación electromagnética en una o más regiones del espectro electromagnético como medio de interacción.

La detección de los objetos de la superficie por sensores alojados en plataformas espaciales, está basada en la energía radiante reflejada o emitida por estos objetos. Cada uno de ellos, dependiendo de sus propiedades físicas y estructurales, del ángulo de incidencia solar y de la longitud de onda de la energía radiante, devolverá hacia el sistema sensor, una cantidad de energía diferente en las diferentes regiones del espectro electromagnético.

La gran cantidad de satélites lanzados en las últimas décadas y la amplia variedad de tipologías de imágenes captadas por estos, ha facilitado la realización de estudios y análisis en diferentes ámbitos muy diversos como la agricultura, la silvicultura, el entorno marino o el ámbito urbano. Una de las aplicaciones más habituales de las imágenes adquiridas por sensores remotos es la identificación de distintos tipos de cubiertas o usos del suelo mediante la aplicación de algoritmos de clasificación, tanto supervisados como no supervisados (Sivakumar, 2003). Estos algoritmos son muy útiles para definir los diferentes elementos que aparecen en la imagen y a través de ellos crear agrupaciones con aquellos que siguen un mismo patrón de comportamiento reflectivo.

Tradicionalmente, la presencia de las sombras en las imágenes satelitales se ha visto percibido como un inconveniente en el procesamiento de estas, ya que en muchas ocasiones las sombras implican pérdida de datos y dificulta la extracción de información de las imágenes adquiridas por sensores remotos. Sin embargo, en los últimos años la presencia de sombras en las imágenes comienza a resultar una oportunidad, ya que puede resultar de utilidad para extraer determinado tipo de información, fundamentalmente relacionada con la geometría de los elementos que aparecen en la imagen. Este cambio de percepción ha sido posible fundamentalmente por el incremento de la resolución espacial en imágenes satelitales, en las que las sombras proyectadas por distintos elementos pueden aprovecharse para determinar la estructura geométrica de estos (Ambrosio *et al.*, 2006).

Las imágenes de muy alta resolución tienen aplicaciones en ámbitos muy diferentes, pero es en el ámbito urbano donde han supuesto un avance muy importante ya que permiten el seguimiento del crecimiento de ciudades, la detección de cambios, la estimación de población y actividades humanas y la extracción y detección de elementos. Es además en las zonas urbanas donde las sombras son más evidentes y donde permiten obtener, indirectamente, información acerca de los elementos que las componen.

Las sombras, aparecen en el momento en el que el rayo incidente, normalmente solar, intercepta con un objeto (Kadhim, Mourshed and Bray, 2015). La creación de las sombras, está condicionada por la fuente de luz, el objeto del cual se formará la sombra y de la superficie donde se proyectará la sombra. En teoría cuanto mayor es el tamaño del objeto, mayor será su sombra, pero en la práctica, especialmente en zonas urbanas, el tema puede resultar mucho más complejo (Kadhim, Mourshed and Bray, 2015). Esto se debe a diferentes factores. Para empezar la existencia tanto de árboles como de vehículos puede distorsionar el contorno de las sombras de los edificios ya que ambas sombras pueden combinarse al

solaparse creando una geometría arbitraria. Otro de los factores es la posición del sol en el momento de adquirirse la imagen. El acimut y la elevación solar serán diferentes en las diferentes épocas del año y diferentes lugares del mundo. En el hemisferio norte, la elevación solar será máximo en el mes de junio, mientras que en hemisferio sur será en el mes de diciembre cuando la altitud del sol será máxima. Cuando la elevación solar toma los valores más altos, las sombras de los objetos suelen ser mayores.

El cálculo de las propiedades geométricas de un edificio a través de las sombras es un tema en el que han trabajado muchos investigadores y por ello existen diferentes metodologías para derivar esta información a partir de imágenes remotas. Una de las más utilizadas es la propuesta por Shettigara and Summerling en 1998. El procedimiento propuesto por estos autores se basa en extraer automáticamente tanto los edificios como las sombras presentes en una imagen mediante la aplicación de algoritmos de clasificación. Una vez identificados los edificios y las sombras, se define la línea que separa el edificio de la sombra y teniendo en cuenta la magnitud de la sombra y la relativa a la posición del sol Enel momento de la adquisición de la imagen, se calculo la altitud de los edificios.

2 – Objetivos

El objetivo principal de este trabajo es aplicar e implementar un procedimiento que permita el cálculo de la altura de edificios en zonas urbanas a partir de la identificación y medición de las sombras presentes en imágenes satelitales de muy alta resolución espacial. Para llevar a cabo el trabajo se han llevado una serie de procesos, cada uno de ellos con su correspondiente propósito:

- Demostrar la utilidad de las imágenes de muy alta resolución espacial para poder determinar la altura de edificios en zonas urbanas a través del análisis de las sombras asociadas a estos edificios.
- Mejorar la resolución espacial de las imágenes multiespectrales con el objeto de poder utilizar la información espectral y espacial para identificar edificios y sombras en zonas urbanas complejas.
- Analizar la utilidad de distintos clasificadores para identificar edificios y sombras en zonas urbanas complejas.
- Implementar un procedimiento sencillo para determinar la altura de edificios teniendo en cuenta la longitud de las sombras y la posición del sol en el momento de la adquisición de la imagen.

3 – Zona de estudio

La zona de estudio corresponde a la ciudad de Melbourne, situada en la zona sureste de Australia. Es la capital del estado de Victoria, el segundo más grande del país tras Tasmania. Es la segunda ciudad más grande de Australia con 4-4.5 millones de habitantes.

La economía de la ciudad se basa en la industria automotriz, además de ser un importante centro financiero y de negocios.

La ciudad se divide en diferentes distritos. En este Trabajo de Fin de Master se trabaja con una imagen recortada, correspondiente a los distritos más céntricos de la ciudad como Melbourne Central, Docklands o Banco Sur. Además de formar la parte central de la capital, estos distritos también conforman la zona financiera, que además de ser un área de negocios importante, también contiene las calles y edificios más históricos.



Figura 1: Representación de la zona de estudio

Los distritos que definen el área de estudio están divididos por el río Yarra. Tiene una longitud de 242 km y desemboca en el mismo Melbourne en bahía de Port Philip. Destacar que en estos distritos son muy abundantes los parques y jardines, que hacen que la ciudad sea conocida como ciudad jardín.

4 – Material

4.1. Imágenes de partida

Las imágenes de partida utilizadas en el trabajo han sido adquiridas por el satélite francés Pleiades 1-A y corresponden a la ciudad de Melbourne en Australia. En este caso se dispone tanto de la imagen adquirida por el sensor pancromático, con una resolución de 0.5 metros y con unas dimensiones de 26426 x 41263 píxeles, como de la imagen adquirida por el sensor multiespectral, con una resolución de 2m y un tamaño de 6573 x 10297 píxeles. Esta segunda imagen está formada por cuatro bandas espectrales, captadas en las longitudes de onda correspondientes a las regiones del azul, verde, rojo e infrarrojo cercano (Airbus, 2014).

Las imágenes fueron capturadas el 25 de febrero de 2012 a las 00:25:59.9 respecto al meridiano Greenwich, 11:25:59.9 hora local. Están proyectadas utilizando como elipsoide de referencia WGS84, en el hemisferio sur, el huso 55. Fueron adquiridas con una orientación de unos 180° y con un ángulo de observación prácticamente cenital, de 1.15 como media.




Figura 2: Imagen pancromática original adquirida con el satélite Pleiades



Figura 3: Imagen multispectral original adquirida con el satélite Pleiades

Para agilizar el procesamiento de las imágenes, se ha recortado la imagen original a los distritos mencionados en el apartado anterior, obteniendo así una imagen pancromática de 8520 x 5760 píxeles y una imagen multispectral de 34080 x 23040 píxeles. El centro de ambas imágenes está definido por las siguientes coordenadas: 37° 49' 01.0" S y 144° 57' 39.3" E.

4.2. Software *Monteverdi*

Para llevar a cabo este trabajo se han utilizado diferentes programas de procesamiento de imágenes, así como sistemas de información geográfica. Además del software de procesamiento de imágenes ENVI, se ha utilizado el software libre *Monteverdi* de Orfeo ToolBox (OTB) para procesar las imágenes de trabajo.

Una librería de herramientas de licencia libre programada en C. Fue desarrollada por *Centre national d'études spatiales* (CNES) con el objetivo de promover, facilitar y simplificar el uso de las imágenes satelitales. Aunque en un principio, la librería estaba enfocada al procesamiento de imágenes de alta resolución adquiridas por los satélites Pleiades y Cosmo-Skymed, hoy en día es posible trabajar con información adquirida por otros sensores tanto ópticos como radar, como SPOT-5, 6 y 7, Sentinel-1, Radarsat-1 y Sentinel-2, además de con imágenes adquiridas por sensores alojados en vehículos aéreos no tripulados (Perez. L, 2018).

Las herramientas ofrecidas por la biblioteca son accesibles mediante QGIS o Python y también por su propio visualizador de imágenes de satélite *Monteverdi*. Este visualizador permite el preprocesamiento de las imágenes satelitales aplicando procesos de calibración radiométrica, ortorrectificación o remuestreo. Ofrece opciones de manipulación de imágenes como la conversión entre ráster/vectorial, la extracción de regiones de interés, álgebra de bandas o filtrado lineal (Orfeo-toolbox, 2019). En cuanto a procesos de clasificación, incluye 9 algoritmos supervisados y también el método de agrupación K-means. Para terminar, también es posible realizar análisis de detección de cambios aplicando por ejemplo técnica

basadas en el análisis de componentes principales. Además, del análisis de imágenes captadas por sensores remotos, también permite el procesado de las imágenes radar.

Por último, comentar que como sistema de información geográfica se ha utilizado el software de código abierto QGIS.

5 – Métodos

A continuación, se describe la metodología que se ha seguido para poder obtener, a partir de las sombras que aparecen en una imagen Pleiades de una zona urbana, la altura de los edificios que generan estas sombras.

En la figura X se muestra la secuencia de procesos aplicados para poder alcanzar el objetivo anterior, que se describe a continuación de forma resumida. Como se ha comentado anteriormente, para abordar este trabajo se dispone de una pareja de imágenes, multiespectral y pancromática, adquiridas simultáneamente sobre la zona de trabajo. La primera proporciona información de las cubiertas en distintas bandas del espectro, lo que resulta fundamental para poder discriminar las sombras y edificios de otras cubiertas, en base a su comportamiento espectral. La segunda, proporciona información en una única banda del espectro, pero con una mayor resolución espacial. Por lo tanto, en una primera fase, se procederá a aplicar un algoritmo de pansharpening con el objeto de obtener la imagen que se aproxime lo máximo posible a la que hubiera adquirido el sensor multiespectral si trabajase a la resolución del pancromático. Este procedimiento se ha llevado a cabo utilizando el algoritmo aditivo proporcional basado en la transformada wavelet *à trous*. A continuación, se ha procedido a clasificar esta imagen multiespectral fusionada con el objeto de extraer los edificios y las sombras presentes en la imagen. El proceso de clasificación supervisada se ha llevado a cabo por fases, de modo que en la primera fase se han considerado en la clasificación las clases sombras, agua y resto, con el objeto de identificar las sombras. En la segunda fase, se han considerado en la clasificación las clases vegetación, agua y resto, aplicando una máscara de sombras, lo que ha permitido identificar las zonas con cubierta vegetal. En la tercera, se han considerado en la clasificación las clases edificios, agua y resto, aplicando una máscara de sombras y vegetación, identificándose de ese modo los edificios presentes en la imagen. Cada una de las clasificaciones se ha llevado a cabo con los clasificadores k-vecinos más próximos o k-nearest neighbor (KNN), basados en máquinas de soporte vectorial o Support Vector Machine (SVM) y basados en bosques aleatorios o Random Forest (RF). Para validar los resultados proporcionados por cada clasificador en cada fase de clasificación, se ha realizado en cada caso una validación cruzada en tres particiones. Una vez identificados los edificios y las sombras, se ha calculado la posición del sol en el momento de la adquisición del sensor, y teniendo en cuenta que el ángulo de observación del sensor ha sido prácticamente nadiral, se ha calculado la longitud de las sombras en la dirección de los rayos solares y con ello, la altura de los edificios.

En la figura que viene a continuación se puede ver el esquema seguido para la realización del trabajo:

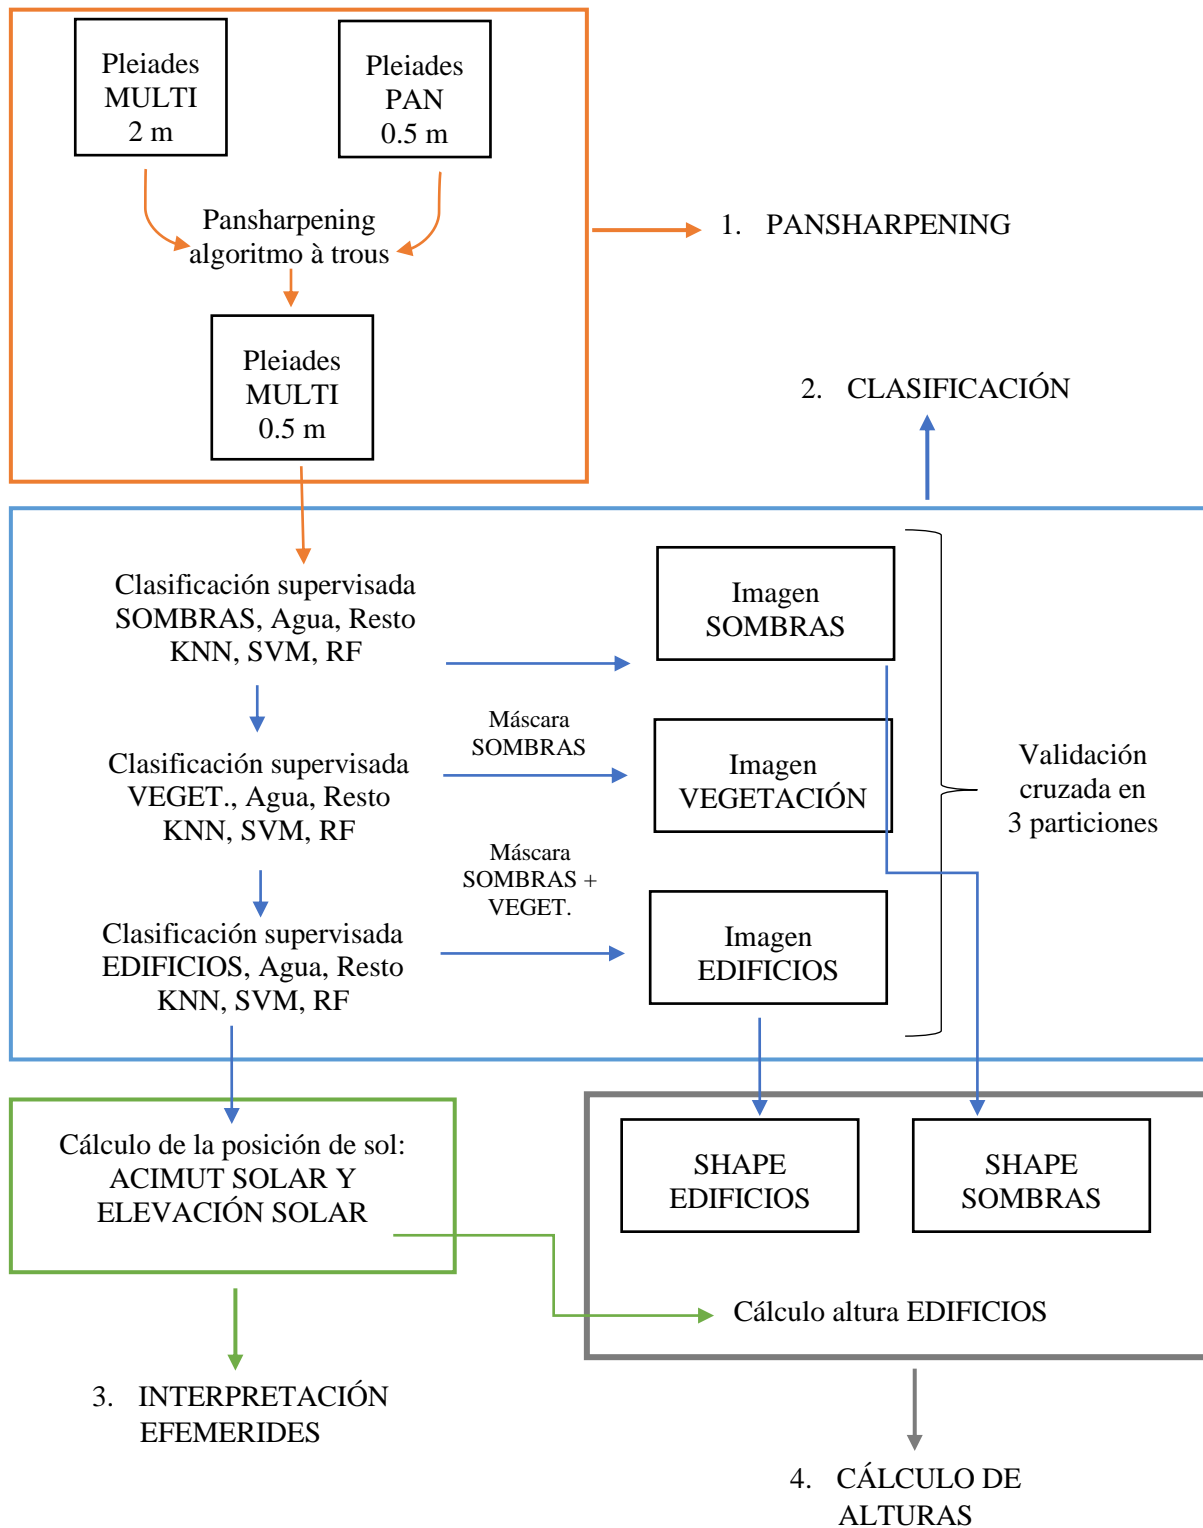


Figura 4: Representación del esquema seguido en el trabajo

5.1. Preprocesamiento de las imágenes: pansharpening o fusión de la multiespectral y pancromática

La fase de preprocesamiento ha consistido en preparar las imágenes de partida para llevar a cabo el trabajo a realizar. Como se ha comentado previamente, se dispone de una pareja de imágenes correspondientes a la ciudad de Melbourne, una multiespectral, con una resolución espacial de 2m y captada en las bandas del espectro correspondientes al azul, verde, rojo e infrarrojo cercano y otra pancromática de 0.5m. Para poder discriminar las sombras y edificios de otros elementos que aparecen en la imagen, es importante trabajar con una imagen multiespectral. A su vez, para poder delimitar con la mayor precisión espacial posible tanto sombras como edificios, es importante poder trabajar con una imagen de alta resolución espacial. Por ello, el objetivo de esta primera parte del trabajo ha sido el de obtener una imagen multiespectral de alta resolución espacial la fusión de ambas imágenes aplicando un algoritmo aditivo basado en la transformada wavelet *à trous*. Se trata de un algoritmo que permite mejorar la resolución espacial, manteniendo a la vez las propiedades e información radiométrica de la imagen multiespectral de partida (González-Audícana *et al.*, 2005).

La idea general del algoritmo de pansharpening basado en la transformada wavelet *à trous* es la de separar la información de la imagen pancromática correspondiente a las altas frecuencias, es decir, el detalle espacial, para luego incorporárselo a la imagen multiespectral de partida.

Para comprender el funcionamiento del algoritmo aditivo basado en la transformada wavelet *à trous* se suele utilizar un esquema basado en un paralelepípedo donde la base del paralelepípedo se corresponde a la imagen pancromática original y cada nivel de la figura será una aproximación de esta imagen. Estas aproximaciones serán el resultado de la aplicación de filtros de paso bajo en la imagen pancromática. Según va subiendo de nivel, las aproximaciones obtenidas van perdiendo resolución, pero a la vez siguen manteniendo el número de píxeles de las filas y columnas. Esto significa que a diferentes niveles del paralelepípedo el detalle espacial se irá perdiendo, por lo que las características físicas en cada nivel serán diferentes.




Figura 5: Representación del esquema de la transformada wavelet *à trous*

En este proyecto se han incorporado a la imagen multiespectral de partida los tres primeros planos wavelet obtenidos de la imagen pancromática ya que, aunque a priori el ratio de resolución espacial teórico entre ambas imágenes es $1:2^2$ y podrían ser suficiente con utilizar los dos primeros planos wavelet, la resolución real de la imagen multiespectral en el proceso de adquisición es algo menor a 2m y por lo tanto, el ratio de resolución puede ser algo

distinto, siendo recomendable incorporar a la imagen multiespectral más detalle de la imagen pancromática (en este caso, el que se corresponde con el detalle espacial observado entre 0.2m y 4m). Esto implica aplicar tres operaciones de filtrado a la imagen pancromática, obteniéndose tres planos wavelet o tres imágenes de detalles espaciales.

Los filtros de paso bajo *à trous* se configuran de modo que permiten ir generando versiones de resolución degradada de la imagen pancromática, denominadas imágenes aproximación. Cada una de las imágenes aproximación tiene la mitad de resolución espacial de la imagen del nivel inmediatamente anterior, aunque mantiene el número de filas y columnas. Es por ello, que para ascender en el paralelepípedo e ir generando imágenes aproximación de menor resolución es necesario ir incorporando ceros al filtro *à trous*, de modo que vaya considerando en cada nivel únicamente los píxeles que le corresponden según su resolución real. A continuación, se muestran los filtros *à trous* aplicados:

Filtro de *à trous* de nivel 1:

$$\begin{pmatrix} 1/2^8 & 1/2^6 & 3/2^7 & 1/2^6 & 1/2^8 \\ 1/2^6 & 1/2^4 & 3/2^5 & 1/2^4 & 1/2^6 \\ 3/2^7 & 3/2^5 & 9/2^6 & 3/2^5 & 3/2^7 \\ 1/2^6 & 1/2^4 & 3/2^5 & 1/2^4 & 1/2^6 \\ 1/2^8 & 1/2^6 & 3/2^7 & 1/2^6 & 1/2^8 \end{pmatrix}$$

Filtro de *à trous* de nivel 2:

$$\begin{pmatrix} 1/2^8 & 0 & 1/2^6 & 0 & 3/2^7 & 0 & 1/2^6 & 0 & 1/2^8 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1/2^6 & 0 & 1/2^4 & 0 & 3/2^5 & 0 & 1/2^4 & 0 & 1/2^6 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 3/2^7 & 0 & 3/2^5 & 0 & 9/2^6 & 0 & 3/2^5 & 0 & 3/2^7 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1/2^6 & 0 & 1/2^4 & 0 & 3/2^5 & 0 & 1/2^4 & 0 & 1/2^6 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1/2^8 & 0 & 1/2^6 & 0 & 3/2^7 & 0 & 1/2^6 & 0 & 1/2^8 \end{pmatrix}$$

Filtro de *à trous* de nivel 3:

$$\begin{pmatrix} 1/2^8 & \dots & 1/2^6 & \dots & 3/2^7 & \dots & 1/2^6 & \dots & 1/2^8 & \dots \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 1/2^6 & \dots & 1/2^4 & \dots & 3/2^5 & \dots & 1/2^4 & \dots & 1/2^6 & \dots \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 3/2^7 & \dots & 3/2^5 & \dots & 9/2^6 & \dots & 3/2^5 & \dots & 3/2^7 & \dots \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 1/2^6 & \dots & 1/2^4 & \dots & 3/2^5 & \dots & 1/2^4 & \dots & 1/2^6 & \dots \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 1/2^8 & \dots & 1/2^6 & \dots & 3/2^7 & \dots & 1/2^6 & \dots & 1/2^8 & \dots \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \end{pmatrix}$$

El detalle espacial que se pierde, al ascender a los niveles superiores del paralelepípedo contiene la información de detalle espacial presente en el nivel inferior y que falta en el superior. La información de detalle de los tres primeros planos wavelet de la imagen

pancromática se corresponde precisamente con la información de detalle espacial que le falta a la imagen multiespectral. Y este detalle, se aplicará de forma aditiva a cada banda de la imagen multiespectral de partida, una vez remuestreada a la resolución de la pancromática. En este proceso suele ser conveniente ponderar la cantidad de detalle que se incorporará a cada banda y es habitual hacerlo mediante el ratio entre la desviación estándar de cada banda y el de la imagen pancromática, aportando así la proporción correspondiente de detalle espacial a cada banda. A continuación, se pueden ver las desviaciones estándar de cada banda y la ponderación aplicada en cada caso al añadir el detalle espacial de la imagen pancromática a las cuatro bandas de la imagen multiespectral.

Tabla 1: Estadísticas y ponderación de cada banda

Banda	Desviación estándar	Ponderación
PAN	375.4599	-
Rojo	329.2318	0.8769
Verde	304.2370	0.8103
Azul	271.0844	0.7220
NIR	410.2550	1.0927

Al analizar la tabla se puede ver que la banda del infrarrojo cercano es la que exige más detalle espacial y que la banda azul será la menos detalle recibirá.

A continuación, se representa el esquema que se ha seguido para aplicar el algoritmo de pansharpening utilizando la transformada wavelet *à trous*:

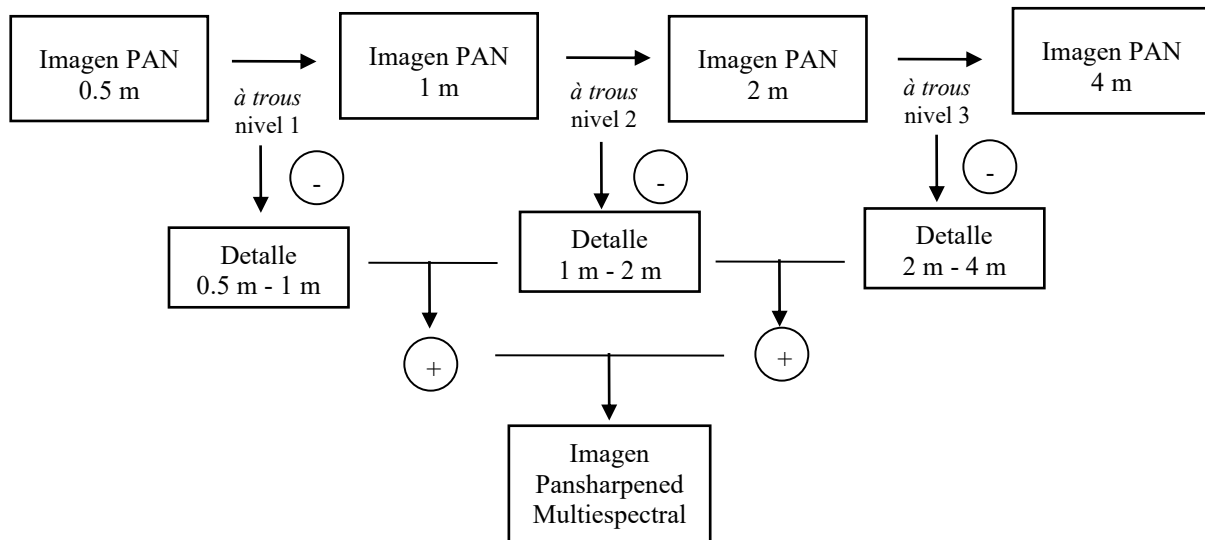


Figura 6: Esquema seguido en la aplicación de la transformada de wavelet *à trous*

5.2. Extracción de sombras y edificios

La imagen de partida para la identificación y extracción de sombras y edificios presentes en la imagen será la multiespectral a 0.5m obtenida tras el proceso de pansharpening del apartado anterior.

El proceso de las clasificaciones se ha aplicado en distintas fases y está orientado a la extracción de diferentes elementos de la imagen de alta resolución: sombras, vegetación y edificios. Señalar que no se ha contemplado una segmentación previa de la imagen y que se trabajará a nivel de píxel.

Como se ha explicado previamente, la clasificación se ha realizado en tres fases: la primera clasificación se ha orientada a la identificación de las sombras, que se utilizarán después para el cálculo de las altitudes de los edificios. Con el objeto de obtener una clasificación lo más precisa posible de los edificios, en una segunda fase, se ha realizado una clasificación orientada a identificar la vegetación, utilizando las sombras como máscara en esta clasificación. Por último, una vez extraídas las sombras y la vegetación se ha aplicado una tercera clasificación para identificar los edificios, utilizando como máscara las capas de sombras y vegetación anteriormente generadas.

Por lo tanto, se han realizado las siguientes clasificaciones:

1. Para la identificación de sombras: partiendo de la imagen multiespectral de muy alta resolución espacial, considerando las clases sombras, agua y resto.
2. Para la identificación de vegetación: partiendo de la imagen multiespectral de muy alta resolución espacial, aplicando la máscara de sombras y considerando las clases vegetación, agua y resto.
3. Para la identificación de edificios: partiendo de la imagen multiespectral de muy alta resolución espacial, aplicando la máscara de sombras y vegetación y considerando las clases edificios, agua y resto.

5.1.1 Definición de las muestras de entrenamiento y test

Para llevar a cabo las clasificaciones de las sombras, vegetación y edificios se ha generado un fichero vectorial mediante la digitalización en pantalla de los distintos elementos, de forma que sea posible determinar su comportamiento espectral típico y entrenar cada uno de los clasificadores. Además, para evaluar la fiabilidad de las clasificaciones se ha seguido una estrategia de validación cruzada en tres particiones de modo que a partir del fichero vectorial de muestras digitalizadas se han creado tres subconjuntos separando en cada caso, un conjunto de entrenamiento, con aproximadamente el 66.6% de las muestras y un conjunto test, con aproximadamente el 33.3% de las muestras. En cada caso, el primer subconjunto se ha utilizado para la obtención del modelo para después utilizarlo en la clasificación y el segundo para evaluar el rendimiento obtenido.

Señalar que el proceso de definición de muestras mediante digitalización y el proceso de subdivisión en particiones realizado para cada elemento a clasificar, es decir, sombras, vegetación y edificios. A partir de un conjunto de información creado mediante digitalización, donde los subconjuntos definidos para cada clase estaban balanceados, es decir, eran parecidos en área, se han obtenido los conjuntos de entrenamiento y de test para cada iteración. Los subconjuntos creados para cada elemento a clasificar han sido los que se pueden ver en la Tabla 2. En todos los casos se ha decidido diferenciar el agua ya que esta muestra un comportamiento espectral que en algunas bandas puede confundirse con los elementos a clasificar.

Tabla 2: Subconjuntos creados para cada uno de las clasificaciones

Clasificación 1: identificación sombras		Clasificación 2: identificación vegetación		Clasificación 3: identificación edificios	
<u>Clase</u>	<u>Área digitalizada (m²)</u>	<u>Clase</u>	<u>Área digitalizada (m²)</u>	<u>Clase</u>	<u>Área digitalizada (m²)</u>
Sombras	43488	Vegetación	33979	Edificios	75248
Agua	43854.	Agua	31641	Agua	73621
Resto	43703	Resto	32691	Resto	74565

Para la clasificación de las sombras, el conjunto de información digitalizado ha sido de 131045 m². En total 41 áreas digitalizadas de las cuales 18 pertenecen a las sombras, 4 al agua y 19 es al resto de elementos que aparecen en la imagen. Del total de muestra, para cada iteración, se han definido los siguientes subconjuntos, intentando en todos los casos que las muestras de cada clase correspondientes a cada subconjunto estén balanceadas:

Tabla 3: Información de la iteración 1 de la clasificación orientada a la identificación de sombras

Conjuntos	Área digitalizada (m ²)	Pixeles	Porcentaje
Conjunto de entrenamiento	86429	345716	66
Conjunto de test	44616	178465	34

Tabla 4: Información de la iteración 2 de la clasificación orientada a la identificación de sombras

Conjuntos	Área digitalizada (m ²)	Pixeles	Porcentaje
Conjunto de entrenamiento	84466	337865	64
Conjunto de test	46579	186317	36

Tabla 5: Información de la iteración 3 de la clasificación orientada a la identificación de sombras

Conjuntos	Área digitalizada (m ²)	Pixeles	Porcentaje
Conjunto de entrenamiento	88023	352092	67
Conjunto de test	43022	172090	33

En el conjunto de test de la primera iteración 44261 pixeles pertenecen a las sombras, 62079 pixeles a agua y 72124 al resto de elementos de la imagen. En la segunda iteración, el conjunto de test está compuesto por 67247 pixeles de sombras, 73714 de agua y 45355 de resto de cubiertas. Para terminar en la tercera iteración 93439 pertenecen a las sombras, 19635 al agua y el resto se compone por 59016 pixeles. Estos conjuntos se utilizarán después para realizar la evaluación del rendimiento de los diferentes modelos obtenidos.

En el caso de la clasificación de la vegetación, se han digitalizado 34 áreas, 98311 m², de las cuales 17 pertenecen a la vegetación, 4 a la clase del agua y 13 al resto. Los conjuntos definidos para cada iteración han sido los siguientes:

Tabla 6: Información de la iteración 1 de la clasificación orientada a la identificación de vegetación

Conjuntos	Área digitalizada (m ²)	Pixeles	Porcentaje
Conjunto de entrenamiento	66732	266929	68
Conjunto de test	31580	126318	32

Tabla 7: Información de la iteración 2 de la clasificación orientada a la identificación de vegetación

Conjuntos	Área digitalizada (m ²)	Píxeles	Porcentaje
Conjunto de entrenamiento	63171	252684	64
Conjunto de test	35141	140563	36

Tabla 8: Información de la iteración 3 de la clasificación orientada a la identificación de vegetación

Conjuntos	Área digitalizada (m ²)	Píxeles	Porcentaje
Conjunto de entrenamiento	65165	260659	66
Conjunto de test	32918	131672	34

Para la comprobación del rendimiento de los modelos de clasificación, se han creado tres conjuntos de test como en el caso anterior. En la primera iteración 66633 píxeles pertenecen a la vegetación, 42444 píxeles al agua y 17241 píxeles al restante. En la segunda iteración, 36717 píxeles son vegetación, 59259 son agua y el resto está compuesto por 44587 píxeles. Para terminar, en la última iteración se han definido 57989 píxeles como vegetación, 53525 píxeles como agua y 20157 como resto.

Para la clasificación de los edificios, se han digitalizado 223433 m², 81 área en total. De estos, 62 áreas pertenecen a los edificios, 4 al agua y 15 al resto de elementos. De este total, se han definido las siguientes tres iteraciones con sus correspondientes conjuntos de entrenamiento y de test:

Tabla 9: Información de la iteración 1 de la clasificación orientada a la identificación de los edificios

Conjuntos	Área digitalizada (m ²)	Píxeles	Porcentaje
Conjunto de entrenamiento	156397	625588	70
Conjunto de test	67037	268146	30

Tabla 10: Información de la iteración 2 de la clasificación orientada a la identificación de los edificios

Conjuntos	Área digitalizada (m ²)	Píxeles	Porcentaje
Conjunto de entrenamiento	143531	574122	64
Conjunto de test	79903	319613	36

Tabla 11: Información de la iteración 3 de la clasificación orientada a la identificación de los edificios

Conjuntos	Área digitalizada (m ²)	Píxeles	Porcentaje
Conjunto de entrenamiento	148084	592338	66
Conjunto de test	75349	301397	34

El conjunto de test se ha compuesto de 134147 píxeles de edificios, 78239 píxeles de agua y 55761 píxeles de resto en la primera iteración. En la segunda iteración, se han definido 161151 píxeles de edificios, 64841 píxeles de agua y 93621 de resto para el conjunto de comprobación. Para terminar en la última iteración, 178303 píxeles pertenecían a la clase de los edificios, 64841 a la clase del agua y el restante estaba compuesto por 58253 píxeles.

5.1.2 Clasificación de la imagen

La calibración y aprendizaje de los clasificadores restados en el trabajo se han llevado a cabo utilizando los conjuntos de entrenamiento expuestos. Los clasificadores testados en este trabajo han sido los siguientes: KNN, SVM y Random Forest.

El clasificador KNN tiene como objetivo principal definir la clase pertenencia de un píxel en base al conocimiento almacenado en el conjunto de entrenamiento, teniendo únicamente en cuenta el vecino más próximo a este, entendiendo como más próximo, con mayor similitud espectral (Sutton, 2012). Está basado en el cálculo de distancias espectrales y se define como un clasificador ‘lazy learner’, es decir, es un tipo de clasificador que retrasa el trabajo todo lo posible.

El algoritmo calcula la distancia entre el píxel a clasificar y los píxeles de entrenamiento para determinar la similitud entre ellos. El parámetro más habitual para determinar la distancia espectral suele ser la euclídea, pero han desarrollado variantes que utilizan otras distancias como la de Manhattan para variables numéricas o Hamming para las variables discretas.

Una vez con todas las distancias calculadas, se definen los k vecinos más cercanos y se clasifica cada píxel a la clase más votada, es decir, a la clase que más se repite. Dependiendo del valor de k , los resultados serán más o menos precisos. En este proyecto se han definido tres diferentes valores para el parámetro k , es decir, tres diferentes cantidades de vecinos a considerar: 5, 30 y 100. Cuando el valor de k es muy pequeño puede ocurrir que queden píxeles pertenecientes a la clase de interés sin incluir y, al contrario, si se define un valor muy elevado, puede que se incluyan píxeles no correspondientes a la clase de interés. Por esta razón, se ha considerado importante analizar los resultados del clasificador utilizando diferentes valores de k .

Otro de los algoritmos aplicados ha sido el de las máquinas de soporte vectorial o SVM. Este clasificador está basado en la minimización del riesgo estructural y tiene como objetivo buscar un hiperplano óptimo que separe las clases a clasificar maximizando el margen a cada lado del hiperplano (Carmona Suárez, 2014).

Una de las principales ventajas de este algoritmo es que, gracias a su capacidad de generalización, es capaz de evitar el problema de sobre--aprendizaje utilizando para esto un parámetro de regularización que, dependiendo de su valor, clasificará mejor o peor las clases. En este trabajo se analizará la influencia de este parámetro, conocido como C en los resultados de la clasificación. Para ello se testarán los resultados obtenidos al aplicar el clasificador considerando los siguientes valores para este parámetro: 1, 100 y 10000.

El último clasificador aplicado ha sido el Random Forest. Este algoritmo obtiene el modelo mediante el uso de diferentes variantes de un mismo clasificador, los árboles de decisión. Cada árbol de decisión genera un resultado independiente de la muestra de entrada, emitiendo un voto simple o ponderado para la clase resultante de cada clasificación (Breiman, 1999). Finalmente, la muestra se clasifica a la clase más votada.

Cada variante de árbol de decisión aplicado se construye mediante la división del conjunto de datos en nodos sucesivos. Esta división se lleva a cabo mediante un atributo del conjunto de

datos que se selecciona mediante la medida de impureza calculada aplicando el índice de Gini. Esta medida calcula la impureza existente de cada atributo respecto a las diferentes clases (Pal, 2005). Al final, el atributo utilizado para la división será el que maximice la impureza. Normalmente el número de atributos utilizado para la división del conjunto de datos en nodos suele ser equivalente a la raíz cuadrada del número total de atributos.

En este trabajo se han definido 50, 100 y 150 nodos de división para analizar los diferentes resultados obtenidos. Por otro lado, el número mínimo de muestras que se han utilizado en la obtención de cada nodo se ha obtenido mediante la raíz cuadrada del total de bandas. En este caso 2.

5.1.3 Análisis de la fiabilidad de la clasificación

Una vez aplicados los distintos clasificadores con diferentes configuraciones y mediante validación cruzada con tres repeticiones, se ha analizado la fiabilidad de cada clasificador y configuración mediante el cálculo de las matrices de confusión, utilizando para ello los diferentes subconjuntos de test. Este proceso también se ha llevado a cabo mediante el software Monteverdi. Las matrices de confusión suelen estar formadas por los datos de referencia (filas) y por los datos de la clasificación generada (columnas) (Rubio *et al.*, 2001). La diagonal de la matriz suele mostrar los píxeles correctamente clasificados, es decir, aquellos píxeles de referencia y píxeles clasificados que coincidan, mientras que en los marginales de la matriz se presentarán los píxeles clasificados erróneamente. A continuación, se puede ver un ejemplo genérico de una matriz de confusión:

Tabla 12: Representación de una matriz de confusión

	Clase 1	Clase 2	Clase 3	...	
Clase 1	X_{11}	X_{12}	X_{13}	...	ΣX_{1n}
Clase 2	X_{21}	X_{22}	X_{23}	...	ΣX_{2n}
...	ΣX_{4n}
	ΣX_{n1}	ΣX_{n2}	ΣX_{n3}	ΣX_{n4}	ΣX_{nn}

A partir de la matriz de confusión es posible calcular diferentes parámetros que permiten la evaluación de los modelos clasificación aplicados. En este trabajo los coeficientes de evaluación elegidos han sido la fiabilidad global y la precisión de la clase de interés en cada caso. El primero, representa el porcentaje de píxeles correctamente clasificados respecto al total evaluado. Con este se ha conseguido tener una idea global del resultado obtenido. El segundo en cambio, se centra en la clase de interés y calcula la precisión con la que se ha clasificado dicha clase.

$$Precisión = \frac{X_{11}}{\Sigma X_{n1}}$$

Como se ha comentado previamente, el análisis de fiabilidad de cada clasificación se ha realizado mediante una validación cruzada con 3 repeticiones, mostrándose en el apartado de resultados la media obtenida para cada clasificador configurado de diferente manera. Una vez generados todos los resultados -de fiabilidad, se ha aplicado el clasificador que mejores

resultados proporciona para clasificar la imagen e identificar sombras, vegetación y edificios, utilizando todo el conjunto de muestras digitalizadas como entrenamiento.

5.3. Cálculo de la posición del sol en el momento de la adquisición de la imagen: ángulos cenital y acimutal del sol

Para poder determinar, a partir de las sombras de los edificios, la altura de los mismos, es necesario conocer con precisión la posición del sol, es decir, los ángulos solares en cada píxel en el momento de adquisición de la imagen. Como en este caso se trabaja con una imagen que cubre una zona de territorio relativamente pequeña, 4 por 3 km, se considerará que los ángulos solares iguales para todos los píxeles de la imagen, y coincidentes con los correspondientes al píxel central. Los ángulos que se van a calcular en este apartado son el de elevación solar y el acimut solar.

Los ángulos solares del centro de la escena figuran en la cabecera de la imagen original, no así los correspondientes a las esquinas de la escena completa. Como en este caso se está trabajando con una subescena de la imagen original, no es posible determinar los ángulos solares correspondientes a la zona de trabajo por interpolación de los de las esquinas. De ahí que se haya considerado conveniente calcularlos teniendo en cuenta la fecha y hora de adquisición y las coordenadas geográficas del centro de la subescena de trabajo.

El proceso del cálculo de estos ángulos exige la obtención de otros parámetros relacionados con la fecha y hora de obtención de la imagen. Para comenzar, partiendo de la fecha y hora de adquisición de la imagen se ha calculado la fracción del año a la que corresponde el día ordinal de adquisición.

$$\gamma = \frac{2\pi}{365} * \left(\text{día}_{del\ año} - 1 + \frac{h_{adq} - 12}{24} \right)$$

Donde el día del año será el día ordinal de adquisición y h_{adq} será el momento exacto de la adquisición de la imagen en horas.

A partir la fracción del año (γ) se ha calculado la ecuación del tiempo. Esta ecuación define la diferencia entre el tiempo solar medio y el tiempo solar aparente.

Este parámetro puede tener una variación de hasta 15 minutos y suele alcanzar su valor máximo a principios de noviembre y a mediados de febrero y valores mínimos los días 15 de abril, 14 de junio, 1 de septiembre y 25 de diciembre. Esto último ocurre cuando el tiempo solar medio y el tiempo solar aparente tienen el mismo valor. La imagen que se está analizando se obtuvo el 25 de febrero, cerca de la fecha en la cual la ecuación del tiempo toma su valor máximo.

$$E = 229.18 * (0.000075 + 0.001868 \cos(\gamma) - 0.032077 \sin(\gamma) - 0.014615 \cos(2\gamma) - 0.040849 \sin(2\gamma))$$

Donde γ será a la fracción del año a la que corresponde el día ordinal de adquisición.

A partir del parámetro anterior se ha determinado la hora solar verdadera. Esta hora determina el momento del paso del Sol por el meridiano en el que se encuentra la localización de interés, en este caso la ciudad de Melbourne.

Para su cálculo es necesario conocer la hora de adquisición de la imagen respecto al meridiano Greenwich, la longitud del punto central de la imagen (Melbourne se encuentra a una longitud de 144° 57' 39.3" E) y el resultado de la ecuación del tiempo.

$$hsv = h_{adq} + \frac{(4 * Long) + E}{60}$$

Donde h_{adq} será el momento exacto de la adquisición de la imagen en horas, long es la longitud correspondiente al centro de la subescena y E será el resultado de la ecuación del tiempo.

Al realizar el cálculo de la hora solar verdadera es importante tener en cuenta la unidad en la que se está trabajando. En este caso el resultado se ha dado en horas. Por esto, se ha transformado primero la longitud a minutos sabiendo que 1° corresponde a 4' de reloj y después se le ha sumado la variación de tiempo. A continuación, se ha convertido este valor a horas. Para terminar con el cálculo, se le ha sumado la hora de adquisición en horas.

Una vez con la hora solar verdadera es posible obtener el ángulo horario. Este ángulo define la distancia entre el meridiano del punto de interés y meridiano del plano donde se encuentra el sol. Tomará el valor de 0° a medio día (12h) e incrementará 15° por cada hora a partir de este momento del día y restará 15° por hora al retroceder hacia horas anteriores al mediodía. Para este caso concreto, el valor tendrá que ser negativo ya que la imagen se ha adquirido antes del mediodía. Su cálculo se lleva a cabo mediante la siguiente ecuación donde hsv corresponde a la hora solar verdadera.

$$w = (hsv - 12) * 15^\circ$$

Otro parámetro necesario para la obtención de los ángulos solares es la declinación solar en la fecha y hora de adquisición de la imagen. Se define como el ángulo entre la línea sol-tierra y el plano ecuatorial y varía entre $\pm 23^\circ$ a lo largo del año. Al ser una ciudad situada en el hemisferio sur la declinación tendrá que ser negativa ya que el sol está por debajo del ecuador. Su cálculo se realiza mediante la aplicación de la fracción del año en una fórmula. Aunque también existen otras maneras de obtenerlo, en este caso se ha aplicado la siguiente ecuación en la cual γ será la fracción del año a la que corresponde el día ordinal de adquisición:

$$\delta = 0.006918 - 0.399912 \cos(\gamma) + 0.070257 \sin(\gamma) - 0.006758 \cos(2\gamma) + 0.000907 \sin(2\gamma) - 0.002697 \cos(3\gamma) + 0.00148 \sin(3\gamma)$$

Una vez se ha calculado tanto la declinación solar como el ángulo horario, se ha procedido al cálculo de los ángulos solares. El ángulo cenital representa la posición del sol respecto al zenit local. La elevación solar se define como el ángulo entre la dirección del sol y el horizonte ideal. Para terminar, el acimut solar define la posición del sol en el momento de la adquisición de la imagen respecto al norte geográfico. En la Figura 7 que viene a continuación vienen representados los distintos ángulos solares:




Figura 7: Representación de los ángulos solares

El ángulo cenital se ha calculado mediante la siguiente expresión donde δ es la declinación solar, lat es la latitud del centro de la subescena y w es el ángulo horario.

$$\cos \varphi = \sin(lat) * \sin(\delta) + \cos(lat) * \cos(\delta) * \cos(w)$$

A partir de este ángulo se ha calculado el ángulo de elevación solar, complementario al ángulo cenital del sol.

Una vez calculada la elevación solar es necesario incorporar una corrección atmosférica por refracción, que se realiza aplicando la siguiente expresión en la cual γ será la fracción del año a la que corresponde el día ordinal de adquisición.

$$refr = \frac{1}{3600} \left[\frac{58.1}{\tan \gamma} - \frac{0.07}{\tan^3 \gamma} + \frac{0.000086}{\tan^5 \gamma} \right]$$

$$\gamma_{correctado} = \gamma + refr = 49.7179$$

Por último, se calcula el acimut solar, que se ha obtenido a través de la siguiente ecuación, donde lat es la latitud del centro de la subescena, φ es el ángulo cenital y δ es la declinación solar.

$$\cos \theta = - \frac{\sin(lat) * \cos(\varphi) - \sin(\delta)}{\cos(lat) * \sin(\varphi)}$$

5.4. Cálculo de las longitudes de las sombras

Una vez identificados tanto edificios como sombras en la imagen, éstos se han vectorizado con el fin de obtener dos capas de polígonos con los que poder trabajar en una herramienta SIG y aplicar operaciones necesarias para el cálculo de la longitud de las sombras.

Para empezar, se ha vectorizado la imagen resultante de la clasificación de las sombras a la cual se le ha aplicado la función de *corregir de geometrías* de QGIS para corregir la geometría de alguna sombra.

A continuación, se ha llevado a cabo la vectorización de los elementos clasificados como edificios. En este caso, al no haber obtenido un resultado tan preciso como el de las sombras, además de corregir la geometría de algún edificio ha sido necesario rellenar agujeros correspondientes a píxeles erróneamente clasificados. Para ello, se ha aplicado la herramienta de *borrar agujeros* de QGIS. El proceso consiste en definir un área mínima y la herramienta rellena todos los anillos que sean menores que esta área definida. El procesamiento de esta capa se ha dividido en distintas fases para agilizar el tiempo del trabajo. Por esto dependiendo de la parte con la que se ha trabajado en cada momento se ha aplicado un área mínima diferente. El rango de valores aplicados está entre 50 y 100 metros cuadrados dependiendo de la cantidad y tamaño de anillos en cada zona de trabajo.

Además de la corrección y relleno de los agujeros también se ha tenido que realizar una limpieza en la capa de los edificios. Este proceso se ha llevado a cabo mediante la aplicación de las herramientas de digitalización avanzada. Para empezar, se ha aplicado la función de *división* para separar bloques de edificios entre sí y también para poder separarlos de otros elementos clasificados erróneamente como edificios, como por ejemplo algunas partes de las carreteras. Otra función utilizada ha sido la de *relleno de anillos*. Esta se ha utilizado en algún caso específico para rellenar algún agujero más grande no corregido anteriormente. Después para unir este nuevo polígono con su bloque correspondiente se ha aplicado la función de *combinación de polígonos*. Por último, en algún caso se ha tenido que dibujar un nuevo polígono para la representación de algún edificio al no tener un polígono que lo representase de manera precisa.

Una vez se han editado todos los bloques en la misma capa, se han calculado los centroides de cada edificio y se les ha asignado un identificador. A continuación, se ha realizado una copia de estos centroides, obteniendo un shape idéntico al de los centroides, únicamente desplazado 254 metros en la dirección del acimut solar. Con esto se ha conseguido por una parte relacionar las sombras con su correspondiente edificio y por otra parte una línea que intersecta con la sombra.



Figura 8: Línea de unión entre el centroide de los edificios y su correspondiente en de la sombra

Para terminar, se ha extraído la intersección entre la línea de unión y la capa de las sombras y se ha realizado el cálculo de la longitud de esta intersección.

5.5. Cálculo de altitudes de los edificios

El último paso del trabajo ha consistido en obtener las altitudes de los edificios de la imagen. Existen diferentes metodologías para realizar el cálculo de las altitudes. Una de las más simples es la aplicación de la trigonometría que relaciona la elevación solar con la longitud de las sombras. Esta metodología fue aplicada por Shettigara y Sumerling (1998) en un proyecto de cálculo de altitudes de edificios mediante sombras utilizando imágenes del satélite SPOT.

Al aplicar este método se asume que la superficie en la que cae la sombra es plana y que en general las sombras no se solapan (Shao, Taff and Walsh, 2011). Además, se asume que el ángulo de observación del sensor es en todos los píxeles de la imagen igual a 0° . En este caso, en la cabecera de la imagen se especifica que ese ángulo es de 1.15° para el centro de la escena. Como este ángulo es muy próximo a 0° y la subescena de trabajo es pequeña, se asume esta hipótesis de modo que la relación entre la elevación solar, la longitud de la sombra y la altura de un objeto, en este caso un edificio, queda representada de la siguiente manera:

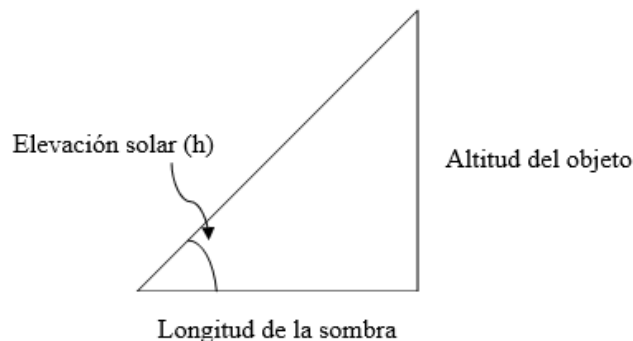


Figura 9: Relación trigonométrica entre la elevación solar, longitud de sombra y la altura de un objeto

Conociendo las relaciones entre los catetos y la hipotenusa de un triángulo recto se puede deducir que:

$$\tan(h) = \frac{\textit{Altitud del objeto}}{\textit{Longitud de la sombra}}$$

6 – Resultados y Discusión

En este apartado del trabajo se expondrán y analizarán los diferentes resultados conseguidos durante el trabajo.

6.1. Preprocesamiento de las imágenes: pansharpening o fusión de la multiespectral y pancromática

En la Figura 10 se muestra la imagen resultante del proceso de pansharpening aplicado a la pareja de imágenes pancromática y multiespectral adquiridas por el satélite Pleiades el 25 de febrero de 2012 y correspondientes a la ciudad de Melbourne. Como se observa en la figura, la imagen pansharpened o fusionada mantiene la información radiométrica de la imagen multiespectral, con la resolución espacial de la pancromática, en este caso, de 0.5m.



Figura 10: Imagen pansharpened obtenida a través de la metodología transformada wavelet *à trous*




Figura 11: Representación detallada de la combinación de la imagen pancromática y la multiespectral

6.2. Extracción de sombras y edificios

En la Tabla 13 se muestran los resultados de fiabilidad obtenidos al aplicar los distintos clasificadores y configuraciones en el primer grupo de clasificaciones, orientado a la identificación de sombras. Los datos de fiabilidad que se muestran en cada caso corresponden a los datos medios obtenidos en la validación cruzada con tres iteraciones.

Al analizar los resultados obtenidos en las diferentes iteraciones se pueden sacar varias conclusiones. Para empezar, viendo las medias obtenidas para las fiabilidades globales de cada clasificador, en el caso del KNN y del SVM los resultados se han mantenido bastante estables en todas las configuraciones aplicadas. El clasificador Random Forest en cambio, sufre una bajada en los tres casos, siendo el clasificador que peores fiabilidades obtiene.

Las precisiones obtenidas siguen el mismo patrón que las fiabilidades globales, obteniendo resultados bastante parecidos con los clasificadores KNN y SVM y una bajada en cuanto a las precisiones del Random Forest.

Tabla 13: Media de las fiabilidades globales y precisiones conseguidas para las sombras

<u>KNN</u>					
k=5		k=30		k=100	
Fiabilidad global (%)	95.9020	Fiabilidad global (%)	95.8985	Fiabilidad global (%)	95.9034
Precisión de sombras (%)	92.0117	Precisión de sombras (%)	91.8786	Precisión de sombras (%)	91.7288
<u>SVM</u>					
c=1		c=100		c=10000	
Fiabilidad global (%)	96.1241	Fiabilidad global (%)	95.6465	Fiabilidad global (%)	93.7629
Precisión de sombras (%)	91.1465	Precisión de sombras (%)	95.4396	Precisión de sombras (%)	91.3268
<u>Random Forest</u>					
Max. depth of the tree = 50		Max. depth of the tree = 100		Max. depth of the tree = 150	
Fiabilidad global (%)	89.8488	Fiabilidad global (%)	91.8685	Fiabilidad global (%)	92.5737
Precisión de sombras (%)	83.5116	Precisión de sombras (%)	85.3858	Precisión de sombras (%)	89.0028

La fiabilidad global máxima se ha conseguido con el clasificador KNN con un valor de consideración de vecinos más cercanos de $k=100$. En el caso de la precisión en cambio es el clasificador SVM con un valor de regularización de 100 el que mayor exactitud ha obtenido.

Teniendo en cuenta que en este trabajo es importante identificar correctamente las sombras, se considera fundamental obtener la máxima precisión posible, por lo que, en base al análisis de los resultados obtenidos se aplica el clasificador SVM con un valor de regularización de 100 para extraer las sombras de la imagen, considerando en esta fase, el 100% de las muestras digitalizadas como entrenamiento.

Teniendo en cuenta la importancia de las sombras en el proyecto. Su buena clasificación es imprescindible para cumplir con el objetivo del trabajo, el cálculo de altitudes de los edificios mediante sombras. Esto significa que en este caso es más importante la precisión de las

sombras que la precisión global de la clasificación. Teniendo todo esto en cuenta se ha aplicado el SVM con un valor de regularización de 100 para extraer las sombras.




Figura 12: Imagen de las sombras clasificadas




Figura 13: Representación detallada de la clasificación de las sombras

Al analizar la clasificación obtenida se puede apreciar que las sombras identificadas están bastante bien definidas y se corresponden con píxeles de sombra en la imagen de trabajo. Esta identificación es buena no sólo en los grandes edificios, sino que también se identifican correctamente las sombras de edificios más bajos e incluso la de la vegetación.

Además, se puede observar que la diferenciación entre la clase de la sombra y la clase del agua ha sido casi perfecta, teniendo en cuenta que, al tener un comportamiento espectral tan parecido, podrían haberse confundido. Lo mismo ha sucedido con la vegetación que en esta fase de clasificación se había incluido en la clase resto.

Como en el caso de las sombras, al realizar la identificación de las vegetaciones también se han obtenido varias matrices de confusión, a partir de las cuales se ha calculado la fiabilidad global y precisión de la clasificación de la vegetación para cada iteración y cada clasificador. Los resultados obtenidos se muestran en la Tabla 14:

En esta segunda clasificación los resultados obtenidos han sido mas variados. Las fiabilidades globales conseguidas para los clasificadores SVM y Random Forest se han mantenido bastante parecidos en general manteniendo una cierta diferencia con los resultados obtenido con el clasificador KNN.

Las precisiones por otro lado sen han mantenido en las diferentes configuraciones de cada clasificador siendo el KNN el que mejores precisiones ha conseguido. En el caso del clasificador SVM se podría mencionar los resultados obtenidos al darle el valor $c=1$ al parámetro de regularización, ya que en este caso tanto la fiabilidad global como la precisión obtenida se salen del patrón que siguen las otras configuraciones del clasificador SVM.

Tabla 14: Media de las fiabilidades globales y precisiones conseguidas para las sombras

<u>KNN</u>					
k=5		k=30		k=100	
Fiabilidad global (%)	82.5612	Fiabilidad global (%)	82.3925	Fiabilidad global (%)	82.3563
Precisión de sombras (%)	99.4516	Precisión de sombras (%)	99.4441	Precisión de sombras (%)	99.4506
<u>SVM</u>					
c=1		c=100		c=10000	
Fiabilidad global (%)	76.0254	Fiabilidad global (%)	70.6123	Fiabilidad global (%)	68.6485
Precisión de sombras (%)	99.9055	Precisión de sombras (%)	96.6645	Precisión de sombras (%)	97.2525
<u>Random Forest</u>					
Max. depth of the tree = 50		Max. depth of the tree = 100		Max. depth of the tree = 150	
Fiabilidad global (%)	70.4273	Fiabilidad global (%)	71.9898	Fiabilidad global (%)	69.3994
Precisión de sombras (%)	98.9213	Precisión de sombras (%)	98.6505	Precisión de sombras (%)	98.6249

Como en la clasificación de las sombras, en este caso también el KNN ha sido el algoritmo que ha obtenido mejores fiabilidades globales. También como en el caso anterior el SVM ha sido el que mayor precisión ha conseguido. En este caso con un valor de regularización de 1. Al analizar tanto las precisiones de los KNN como la fiabilidad del SVM ($c=1$), se puede concluir que las precisiones del primer algoritmo se acercan mucho al de la máquina de soporte vectorial. La fiabilidad global en cambio ha disminuido en un 5% respecto al KNN.

La vegetación identificada en esta fase y las sombras aplicadas en la fase anterior se aplican como mascarás al proceso de clasificación orientado a la identificación de los edificios. La identificación y delimitación precisa de los edificios también tiene su importancia de cara a los objetivos del trabajo por lo que conseguir una máscara de vegetación que sea los más ajustada a la realidad posible, es primordial. Por esto, esta vez también se han tenido más en cuenta los valores de precisión en la identificación de vegetación. Es cierto que los KNN en

las tres configuraciones han conseguido resultados muy buenos también y aparte de esto al tener las mejores fiabilidades cualquiera de ellos sería una buena opción para la clasificación, pero el SVM ha obtenido una precisión casi perfecta de media y aunque su fiabilidad disminuya respecto al otro clasificador en este caso es más interesante obtener una buena extracción de la vegetación.



Figura 14: Imagen de la vegetación clasificada aplicando una máscara de sombras




Figura 15: Representación detallada de la clasificación de la vegetación

Posiblemente los buenos resultados respondan al hecho de que las cubiertas vegetales son bastante homogéneas en esta zona. Además, la máscara de sombras utilizada en esta fase de clasificación ha permitido minimizar la confusión entre estas y las cubiertas vegetales. Como en el caso de las sombras, también existía la posibilidad de que la vegetación se pudiera confundir con las masas de agua por su comportamiento espectral similar en el visible, pero no ha sido el caso.

Por último, en la Tabla 15 se muestran los resultados de fiabilidad y precisión obtenidos al aplicar los distintos clasificadores y configuraciones en el último grupo de clasificaciones, orientado a la identificación de edificios. Como en los casos anteriores, los datos de fiabilidad corresponden a los datos medios obtenidos en la validación cruzada con tres iteraciones.

Los resultados conseguidos para esta última clasificación de los edificios, en general, muestran unas fiabilidades bastante estables en las diferentes configuraciones de cada clasificador, aunque existe algún valor en el caso del clasificador SVM y del clasificador Random Forest que se sale del patrón. En lo obtenido para las precisiones sucede lo mismo, en general las diferentes configuraciones de cada clasificador obtienen resultados bastante similares, exceptuando que en el clasificador SVM existe un valor que mantiene una diferencia respecto al resto de resultados de este mismo clasificador.

Tabla 15: Media de las fiabilidades globales y precisiones conseguidas para las sombras

<u>KNN</u>					
k=5		k=30		k=100	
Fiabilidad global (%)	73.1543	Fiabilidad global (%)	73.1063	Fiabilidad global (%)	73.1286
Precisión de sombras (%)	72.5153	Precisión de sombras (%)	72.4951	Precisión de sombras (%)	72.4969
<u>SVM</u>					
c=1		c=100		c=10000	
Fiabilidad global (%)	70.2419	Fiabilidad global (%)	75.8895	Fiabilidad global (%)	74.5656
Precisión de sombras (%)	70.8823	Precisión de sombras (%)	75.3068	Precisión de sombras (%)	73.3068
<u>Random Forest</u>					
Max. depth of the tree = 50		Max. depth of the tree = 100		Max. depth of the tree = 150	
Fiabilidad global (%)	72.5153	Fiabilidad global (%)	72.4951	Fiabilidad global (%)	70.9435
Precisión de sombras (%)	70.1596	Precisión de sombras (%)	68.9814	Precisión de sombras (%)	69.0072

Tal y como se muestra en la Tabla 15, en este caso tanto la mayor fiabilidad global como la mayor precisión se ha obtenido con el clasificador SVM, con un valor de regularización de 100, por lo que al modelo que se entrena con el 100% de las muestras digitalizadas para la identificación de edificios, se le aplica este clasificador y configuración.



Figura 16: Imagen de los edificios clasificados aplicando una máscara de sombras y vegetación




Figura 17: Representación detallada de la clasificación de los edificios

El resultado que ha obtenido para la clasificación de edificios puede considerarse aceptable teniendo en cuenta que se está trabajando en una zona urbana de una ciudad en la que los edificios no suelen seguir un patrón en cuanto a la tonalidad y aspecto de las cubiertas. Como en las clasificaciones anteriores, se considera muy positivo la aplicación de las máscaras de sombras y vegetación a la imagen a clasificar ya que ha contribuido a discriminar estos elementos que podrían afectar a la clasificación de edificios, consiguiéndose de este modo un resultado más preciso.

6.3. Cálculo de la posición del sol en el momento de la adquisición de la imagen: ángulos cenital y acimutal del sol

Los ángulos solares del centro de la escena resultantes para el momento de la adquisición de la imagen han sido de 49.7179° para la elevación solar y de 53.7440° para el acimut solar.

Estos datos se han comparado con los proporcionados en la cabecera de la escena, que hay que recordar que son ángulos para pixel central de la escena completa (Tabla 16).

Tabla 16: Ángulos solares dados por la cabecera de la imagen original

Ángulo	Mitad
Elevación solar	49.7424
Acimut solar	53.6912

Al comparar los ángulos obtenidos mediante los cálculos realizados, con los que proporciona la cabecera, se puede concluir que los resultados obtenidos siguen una lógica. El centro de la subescena con la que se ha trabajado se encuentra al noroeste del centro de la escena original y por esto el resultado obtenido para la elevación solar es mas bajo y el acimut solar más alto.

6.4. Cálculo de las altitudes de los edificios

Antes de realizar el cálculo de las altitudes ha sido necesario obtener las sombras vectorizadas para poder determinar su longitud y calcular las altitudes a partir de estos resultados. Solo se les ha aplicado un corrector de geometrías sin realizar ninguna división de los bloques ya que en este caso no era necesario porque su longitud la definiría la intersección entre el centroide del edificio y el complementario de este desplazado en dirección del acimut solar. El resultado obtenido ha sido muy preciso obteniéndose además de las sombras de edificios, también las de árboles, aunque estos son más pequeños y por lo tanto más difíciles de definir. En algunos casos la sombra de objeto de interés no se ha podido extraer. Esto en general ha sucedido en los bloques donde existían más un edificio uno al lado del otro y las sombras a penas se apreciaban.




Figura 18: Sombras vectorizadas y corregidas

En la vectorización del ráster de los edificios se ha realizado una selección de estos. En la imagen original en realidad existen más edificios, pero no se han podido extraer todos. Por una parte, en la clasificación han quedado bloques sin identificar. Por otra parte, al realizar la

limpieza de la capa también se han encontrado construcciones como los campos de fútbol o puentes que también se han eliminado. Además, en este proceso de limpieza de la capa vectorial se han descartado algunos edificios que, al no tener una sombra definida, por estar pegada a otro edificio, no podrían incluirse en el cálculo de alturas. En conclusión, al final de este proceso se han definido 3133 edificios cada uno de ellos con su respectivo centroide.



Figura 19: Edificios vectorizados con sus correspondientes centroides

Partiendo de los 3133 edificios definidos se han obtenido las intersecciones para el cálculo de las longitudes de las sombras. En este caso también ha sido necesario realizar una limpieza, teniendo en cuenta la capa de las sombras, para obtener únicamente la intersección correspondiente a cada edificio. En este proceso también se han tenido que descartar algunos edificios. En algunos casos, como se ha mencionado anteriormente, no había sombras definidas por su localización y en otros casos se ha tomado la decisión de no tener en cuenta algún edificio porque su sombra se veía afectada por elementos ajenos como árboles o coches. Al final del proceso se ha obtenido la longitud de sombra para 2255 edificios. A continuación, se muestran las longitudes de algunos de ellos a modo de ejemplo:

Tabla 17: Ejemplos de los resultados obtenidos para las longitudes de las sombras de los edificios

ID del edificio	Longitud de la sombra (m)
2933	4.921
3111	9.756
179	116.677
52	34.145
180	15.853
4	5.691
3109	6.975
234	131.701
2	42.129
2220	7.912

Para terminar, se ha realizado el cálculo de las altitudes considerando la longitud de sombras y la elevación solar. En la Figura 20 se muestra un gráfico en el que se puede ver cuantos edificios de cada rango de altura se han conseguido:

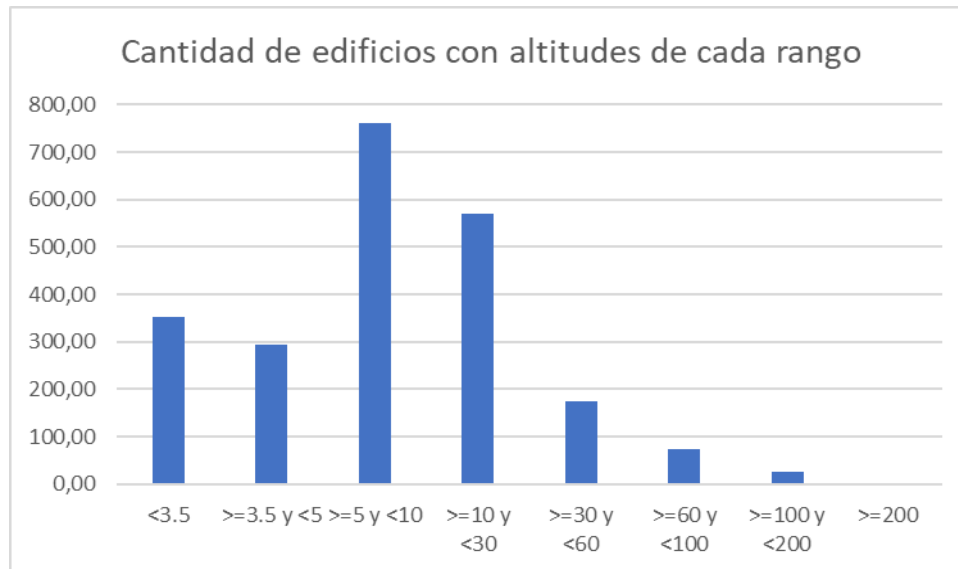


Figura 20: Grafico de la cantidad de edificios en cada rango de altitudes

Los resultados muestran que la mayoría de los edificios se encuentran entre 60 y 10 metros. Teniendo en cuenta que cada piso residencial mide de media 3.5 m se puede concluir que la mayoría de los edificios de la subescena de Melbourne tiene entre 3 y 17 pisos. También existen edificios con mas altitud, pero son la minoría de los casos. En cuanto a las altitudes menores que 3.5 podría ser casos en los que las sombras no estuvieran bien definidas por lo que no se ha podido realizar un calculo correcto de estos edificios.

7 – Conclusiones

A continuación, se muestran las conclusiones derivadas del análisis de los resultados obtenidos en este trabajo:

- El algoritmo de pansharpening aditivo proporcional basado en la transformada wavelet á trous, ha permitido obtener una imagen multiespectral de muy alta resolución espacial, en este caso, de 0.5m. La resolución espectral de la imagen ha resultado suficiente para la identificación de sombras y edificios y a su vez, la resolución espacial de 0.5m ha resultado suficiente para definir de forma bastante precisa la geometría de estos elementos.

La metodología propuesta por Shettigara and Sumerling (1998) para la identificación de sombras y edificios mediante algoritmos de clasificación ha permitido obtener resultados con valores de precisión altos en un entorno complejo como el de la ciudad de Melbourne. Además, el análisis de distintos clasificadores y configuraciones, ha permitido comprobar que en general, cualquiera de los clasificadores analizados proporciona buenos resultados si la muestra de entrenamiento es suficientemente representativa de los elementos a identificar y está bien balanceada entre clases.

- La clasificación de cubiertas por fases, comenzando por sombras, vegetación y terminando por edificios, aplicando en cada fase la máscara de cubierta identificada en la anterior, ha permitido obtener valores altos de fiabilidad y precisión en la extracción de esta información.
- El tratamiento de la información vectorial derivada de las imágenes ráster de sombras y edificios ha permitido definir la línea de acimut solar asociada a cada edificio y a partir de estas, la longitud de las sombras correspondientes. Como el ángulo de observación del sensor es muy próximo a cero en toda la imagen, el cálculo de las altitudes se ha realizado a partir de la longitud de las sombras, teniendo únicamente en cuenta el ángulo de elevación solar en el momento de la adquisición de la imagen.

8 – Bibliografía

- Airbus. 2014. “Geo-Intelligence Pléiades Spot the Detail.” Airbus Defences and Space, 1–2. https://www.intelligence-airbusds.com/files/pmedia/public/r61_9_geo_011_pleiades_en_low.pdf
- Ambrosio, G. *et al.* (2006) ‘Detección de sombras en imágenes de satélite de alta resolución Quickbird’, *XXVII Jornadas de Automática*, pp. 1306–1312.
- Breiman, L. (1999) ‘Random Forests-Random Features’, pp. 1–29.
- Carmona Suárez, E. J. (2014) *Tutorial sobre Máquinas de Vectores Soporte (SVM)*.
- González-Audicana, M. *et al.* (2005) ‘Comparison between Mallat’s and the “à trous” discrete wavelet transform based algorithms for the fusion of multispectral and panchromatic images’, *International Journal of Remote Sensing*. Taylor and Francis Ltd., 26(3), pp. 595–614. doi: 10.1080/01431160512331314056.
- Kadhim, N. M. S. M., Mourshed, M. and Bray, M. T. (2015) ‘Shadow detection from very high resolution satellite image using grabcut segmentation and ratio-band algorithms’, in *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*. International Society for Photogrammetry and Remote Sensing, pp. 95–101. doi: 10.5194/isprsarchives-XL-3-W2-95-2015.
- Orfeo-toolbox.org. (2019). *Monteverdi — OTB Cookbook 6.6.1 documentation*. [online] Available at: <https://www.orfeo-toolbox.org/CookBook/Monteverdi.html>.
- Perez, L. (2018) "Visualización de imágenes de satélite de Monteverdi (Orfeo Toolbox)", *Acolita*. Available at: <https://acolita.com/visualizacion-imagenes-satelite-monteverdi-orfeo-toolbox/>.
- Pal, M. (2005) *Random Forest Classifier for Remote Sensing Classification*.
- Rubio, E. *et al.* (2001) *Clasificación del viñedo de la zona de Tomelloso (Albacete), Teledetección, Medio Ambiente y Cambio Global*.
- Shao, Y., Taff, G. N. and Walsh, S. J. (2011) ‘Shadow detection and building-height estimation using IKONOS data’, *International Journal of Remote Sensing*, 32(22), pp. 6929–6944. doi: 10.1080/01431161.2010.517226.
- Shettigara, V. K. and Sumerling, G. M. (1998) ‘Height determination of extended objects using shadows in SPOT images’, *Photogrammetric Engineering and Remote Sensing*, pp. 35–44.

Sivakumar, M V K, P S Roy, K Harmsen, and S K Saha. 2003. "Satellite Remote Sensing and GIS Applications in Agricultural Meteorology World Meteorological Organization (WMO) India Meteorological Department (IMD) Centre for Space Science and Technology Education in Asia and the Pacific (CSSTEAP) Indian Institute of Remote Sensing (IIRS) National Remote Sensing Agency (NRSA) and Space Application Centre (SAC)." <http://www.bishensinghbooks.com>.

Sutton, O. (2012) *Introduction to k Nearest Neighbour Classification and Condensed Nearest Neighbour Data Reduction*.

ANEXOS

ANEXO I: Matrices de confusión de las clasificaciones

Matrices de confusión de la clasificación de las sombras:

Iteración 1

KNN								
k=5			k=30			k=100		
43096	19	1144	43089	19	1151	43158	19	1082
9209	47962	4912	9457	47964	4662	9750	47959	4374
1577	104	70441	1616	102	70404	1631	105	70386
TOTAL	<u>178464</u>		TOTAL	<u>178464</u>		TOTAL	<u>178464</u>	

SVM								
c=1			c=100			c=10000		
42521	59	1679	43002	34	1223	43847	24	388
12674	49148	261	2869	48541	10673	748	48171	13164
1154	169	70799	1175	157	70790	5768	529	65825
TOTAL	<u>178464</u>		TOTAL	<u>178464</u>		TOTAL	<u>178464</u>	

Random Forest								
Max Depth=50			Max Depth=100			Max Depth=150		
42948	77	1234	42616	366	1277	42808	245	1206
14490	35377	12216	13692	47043	1348	3758	47083	11242
4545	548	67029	6332	1621	64169	8571	721	62830
TOTAL	<u>178464</u>		TOTAL	<u>178464</u>		TOTAL	<u>178464</u>	

Iteración 2

KNN								
k=5			k=30			k=100		
66516	441	307	66515	442	307	66508	441	315
207	73487	18	212	73486	14	207	73491	14
1273	34	44050	1252	34	44071	1277	34	44046
TOTAL	<u>186333</u>		TOTAL	<u>186333</u>		TOTAL	<u>186333</u>	

SVM								
c=1			c=100			c=10000		
66123	864	277	66375	563	326	66435	475	354
16	73607	89	41	73463	208	17	73297	398
896	152	44309	986	61	44310	6695	34	38628
TOTAL	<u>186333</u>		TOTAL	<u>186333</u>		TOTAL	<u>186333</u>	

Random Forest								
Max Depth=50			Max Depth=100			Max Depth=150		
65967	623	674	65727	745	792	65849	631	784
8451	63677	1584	3253	67004	3455	4445	67648	1619
3960	273	41124	3140	188	42029	1526	282	43549
TOTAL	<u>186333</u>		TOTAL	<u>186333</u>		TOTAL	<u>186333</u>	

Iteración 3

KNN								
k=5			k=30			k=100		
92536	742	161	92535	735	169	92539	733	167
0	19643	0	0	19643	0	0	19643	0
1668	121	57220	1664	119	57226	1661	120	57228
TOTAL	<u>172091</u>		TOTAL	<u>172091</u>		TOTAL	<u>172091</u>	

SVM								
c=1			c=100			c=10000		
91971	1352	116	92493	832	114	92543	711	185
0	19643	0	0	19643	0	0	19643	0
611	388	58010	3416	541	55052	3761	295	54953
TOTAL	<u>172091</u>		TOTAL	<u>172091</u>		TOTAL	<u>172091</u>	

Random Forest								
Max Depth=50			Max Depth=100			Max Depth=150		
90488	2339	612	90342	1963	1134	90977	1925	537
0	19643	0	4	19637	2	1	19633	9
2722	432	55855	2801	1632	54576	2157	310	56542
TOTAL	<u>172091</u>		TOTAL	<u>172091</u>		TOTAL	<u>172091</u>	

Matrices de confusión de la clasificación de la vegetación:

Iteración 1

KNN								
k=5			k=30			k=100		
66615	0	0	66615	0	0	66615	0	0
91	28316	14033	92	28341	14007	93	28331	14016
0	0	17239	0	0	17239	0	0	17239
TOTAL	<u>126294</u>		TOTAL	<u>126294</u>		TOTAL	<u>126294</u>	

SVM								
c=1			c=100			c=10000		
66615	0	0	66615	0	0	66615	0	0
184	28625	13631	6642	28499	7299	5241	28375	8824
0	0	17239	765	0	16474	730	0	16509
TOTAL	<u>126294</u>		TOTAL	<u>126294</u>		TOTAL	<u>126294</u>	

Random Forest								
Max Depth=50			Max Depth=100			Max Depth=150		
66597	0	18	65876	0	739	66607	0	8
257	27457	14726	265	27188	14987	510	27275	14655
2	3	17234	395	141	16703	577	16	16646
TOTAL	<u>126294</u>		TOTAL	<u>126294</u>		TOTAL	<u>126294</u>	

Iteración 2

KNN								
k=5			k=30			k=100		
36752	0	0	36752	0	0	36752	0	0
0	10582	48695	0	8068	51209	0	11743	47534
563	1	44023	571	1	44015	563	1	44023
TOTAL	<u>140616</u>		TOTAL	<u>140616</u>		TOTAL	<u>140616</u>	

SVM								
c=1			c=100			c=10000		
36752	0	0	36752	0	0	36752	0	0
0	13121	46156	0	8906	50371	0	859	58418
3	46	44538	0	0	44587	6	0	44581
TOTAL	<u>140616</u>		TOTAL	<u>140616</u>		TOTAL	<u>140616</u>	

Random Forest								
Max Depth=50			Max Depth=100			Max Depth=150		
36715	10	27	36730	0	22	36711	10	31
9	6168	53100	1	5443	53833	0	5759	53518
1056	77	43454	1126	38	43423	916	78	43593
TOTAL	<u>140616</u>		TOTAL	<u>140616</u>		TOTAL	<u>140616</u>	

Iteración 3

KNN								
k=5			k=30			k=100		
57903	65	22	57903	65	22	57905	64	21
0	46139	7383	0	47812	5710	0	44230	9292
0	564	19582	0	568	19578	0	569	19577
TOTAL	<u>131658</u>		TOTAL	<u>131658</u>		TOTAL	<u>131658</u>	

SVM								
c=1			c=100			c=10000		
57903	74	13	57878	100	12	57884	85	21
0	17199	36323	0	464	53058	0	231	53291
0	620	19526	0	411	19735	0	308	19838
TOTAL	<u>131658</u>		TOTAL	<u>131658</u>		TOTAL	<u>131658</u>	

Random Forest								
Max Depth=50			Max Depth=100			Max Depth=150		
57296	31	663	57817	65	108	57442	21	527
0	4238	49284	13	12245	41264	0	1214	52308
17	345	19784	33	406	19707	49	446	19651
TOTAL	<u>131658</u>		TOTAL	<u>131658</u>		TOTAL	<u>131658</u>	

Matrices de confusión de la clasificación de los edificios:

Iteración 1

KNN								
k=5			k=30			k=100		
111769	1549	20859	111685	1530	20962	111644	1541	20992
14072	64169	0	14100	64141	0	14077	64164	0
29009	0	26749	28895	0	26863	29016	0	26742
TOTAL	<u>268176</u>		TOTAL	<u>268176</u>		TOTAL	<u>268176</u>	

SVM								
c=1			c=100			c=10000		
106779	3370	24028	111358	1654	21165	111082	1354	21741
10823	67403	15	13677	64557	7	13783	64458	0
30313	1	25444	18568	0	37190	20620	0	35138
TOTAL	<u>268176</u>		TOTAL	<u>268176</u>		TOTAL	<u>268176</u>	

Random Forest								
Max Depth=50			Max Depth=100			Max Depth=150		
113603	970	19604	113668	902	19607	113608	966	19603
17517	60719	5	19036	59204	1	17760	60480	1
27066	0	28692	26434	0	29324	26947	0	28811
TOTAL	<u>268176</u>		TOTAL	<u>268176</u>		TOTAL	<u>268176</u>	

Iteración 2

KNN								
k=5			k=30			k=100		
128032	1228	31906	128001	1221	31944	127971	1226	31969
68	64776	0	69	64775	0	77	64767	0
64228	87	29303	64293	85	29240	64256	86	29276
TOTAL	<u>319628</u>		TOTAL	<u>319628</u>		TOTAL	<u>319628</u>	

SVM								
c=1			c=100			c=10000		
124770	4002	32394	132261	1124	27781	132733	616	27817
53	64791	0	52	64792	0	212	64632	0
81873	338	11407	65473	110	28035	72503	52	21063
TOTAL	<u>319628</u>		TOTAL	<u>319628</u>		TOTAL	<u>319628</u>	

Random Forest								
Max Depth=50			Max Depth=100			Max Depth=150		
130373	601	30192	131298	418	29450	130597	453	30116
4813	60031	0	15696	49148	0	15522	49322	0
66945	40	26633	66792	35	26791	66956	35	26627
TOTAL	<u>319628</u>		TOTAL	<u>319628</u>		TOTAL	<u>319628</u>	

Iteración 3

KNN								
k=5			k=30			k=100		
138462	1179	38672	138163	1168	38982	138491	1154	38668
41	64803	0	40	64804	0	43	64801	0
37216	76	20965	37264	77	20916	37230	76	20951
TOTAL	<u>301414</u>		TOTAL	<u>301414</u>		TOTAL	<u>301414</u>	

SVM								
c=1			c=100			c=10000		
130965	3885	43463	144134	1301	32878	141820	850	35643
48	64796	0	45	64799	0	460	64384	0
32502	243	25512	32664	80	25513	32949	29	25279
TOTAL	<u>301414</u>		TOTAL	<u>301414</u>		TOTAL	<u>301414</u>	

Random Forest								
Max Depth=50			Max Depth=100			Max Depth=150		
147190	454	30669	147134	481	30698	147517	466	30330
11571	53273	0	11741	53103	0	12244	52600	0
39706	26	18525	39683	23	18551	39669	27	18561
TOTAL	<u>301414</u>		TOTAL	<u>301414</u>		TOTAL	<u>301414</u>	

ANEXO II: Fiabilidades globales y precisiones obtenidas para cada clasificación

Fiabilidades global y precisiones de la clasificación de las sombras:

Iteración 1					
<u>KNN</u>					
k=5		k=30		k=100	
Fiabilidad global (%)	90.4939	Fiabilidad global (%)	90.4703	Fiabilidad global (%)	90.4961
Precisión de sombras (%)	79.9822	Precisión de sombras (%)	79.5558	Precisión de sombras (%)	79.1324
<u>SVM</u>					
c=1		c=100		c=10000	
Fiabilidad global (%)	91.0368	Fiabilidad global (%)	90.9612	Fiabilidad global (%)	88.4453
Precisión de sombras (%)	75.4601	Precisión de sombras (%)	91.4042	Precisión de sombras (%)	87.0619
<u>Random Forest</u>					
Max. depth of the tree = 50		Max. depth of the tree = 100		Max. depth of the tree = 150	
Fiabilidad global (%)	81.4472	Fiabilidad global (%)	86.1955	Fiabilidad global (%)	85.5752

Precisión de sombras (%)	69.2900	Precisión de sombras (%)	68.0332	Precisión de sombras (%)	77.6393
--------------------------	---------	--------------------------	---------	--------------------------	---------

Iteración 2					
<u>KNN</u>					
k=5		k=30		k=100	
Fiabilidad global (%)	98.7764	Fiabilidad global (%)	98.7866	Fiabilidad global (%)	98.7721
Precisión de sombras (%)	97.8234	Precisión de sombras (%)	97.8464	Precisión de sombras (%)	97.8174
<u>SVM</u>					
c=1		c=100		c=10000	
Fiabilidad global (%)	98.7689	Fiabilidad global (%)	98.8274	Fiabilidad global (%)	95.7211
Precisión de sombras (%)	98.6395	Precisión de sombras (%)	98.4763	Precisión de sombras (%)	90.8240
<u>Random Forest</u>					
Max. depth of the tree = 50		Max. depth of the tree = 100		Max. depth of the tree = 150	
Fiabilidad global (%)	91.6467	Fiabilidad global (%)	93.7891	Fiabilidad global (%)	95.0159
Precisión de sombras (%)	84.1652	Precisión de sombras (%)	91.1356	Precisión de sombras (%)	91.6862

Iteración 3					
<u>KNN</u>					
k=5		k=30		k=100	
Fiabilidad global (%)	98.4357	Fiabilidad global (%)	98.4386	Fiabilidad global (%)	98.4421
Precisión de sombras (%)	98.2294	Precisión de sombras (%)	98.2335	Precisión de sombras (%)	98.2367
<u>SVM</u>					
c=1		c=100		c=10000	
Fiabilidad global (%)	98.5665	Fiabilidad global (%)	97.1509	Fiabilidad global (%)	97.1225
Precisión de sombras (%)	99.3400	Precisión de sombras (%)	96.4383	Precisión de sombras (%)	96.0947
<u>Random Forest</u>					
Max. depth of the tree = 50		Max. depth of the tree = 100		Max. depth of the tree = 150	
Fiabilidad global (%)	96.4525	Fiabilidad global (%)	95.6209	Fiabilidad global (%)	97.1300
Precisión de sombras (%)	97.0797	Precisión de sombras (%)	96.9886	Precisión de sombras (%)	97.6829

Fiabilidades global y precisiones de la clasificación de la vegetación:

Iteración 1					
<u>KNN</u>					
k=5		k=30		k=100	
Fiabilidad global (%)	88.8166	Fiabilidad global (%)	88.8364	Fiabilidad global (%)	88.8284
Precisión de sombras (%)	99.8636	Precisión de sombras (%)	99.8621	Precisión de sombras (%)	99.8606
<u>SVM</u>					
c=1		c=100		c=10000	
Fiabilidad global (%)	89.0612	Fiabilidad global (%)	88.3557	Fiabilidad global (%)	88.2853
Precisión de sombras (%)	99.7245	Precisión de sombras (%)	89.9935	Precisión de sombras (%)	91.7739
<u>Random Forest</u>					
Max. depth of the tree = 50		Max. depth of the tree = 100		Max. depth of the tree = 150	
Fiabilidad global (%)	88.1182	Fiabilidad global (%)	86.9139	Fiabilidad global (%)	87.5164
Precisión de sombras (%)	99.6126	Precisión de sombras (%)	99.0081	Precisión de sombras (%)	98.3942

Iteración 2					
<u>KNN</u>					
k=5		k=30		k=100	
Fiabilidad global (%)	64.9691	Fiabilidad global (%)	63.1756	Fiabilidad global (%)	65.7948
Precisión de sombras (%)	98.4912	Precisión de sombras (%)	98.4701	Precisión de sombras (%)	98.4912
<u>SVM</u>					
c=1		c=100		c=10000	
Fiabilidad global (%)	67.1410	Fiabilidad global (%)	64.1783	Fiabilidad global (%)	58.4514
Precisión de sombras (%)	99.9918	Precisión de sombras (%)	100.0000	Precisión de sombras (%)	99.9837
<u>Random Forest</u>					
Max. depth of the tree = 50		Max. depth of the tree = 100		Max. depth of the tree = 150	
Fiabilidad global (%)	61.3991	Fiabilidad global (%)	60.8722	Fiabilidad global (%)	61.2043
Precisión de sombras (%)	97.1810	Precisión de sombras (%)	97.0230	Precisión de sombras (%)	97.5656

Iteración 3					
<u>KNN</u>					
k=5		k=30		k=100	
Fiabilidad global (%)	93.8978	Fiabilidad global (%)	95.1655	Fiabilidad global (%)	92.4456
Precisión de sombras (%)	100.0000	Precisión de sombras (%)	100.0000	Precisión de sombras (%)	100.0000
<u>SVM</u>					
c=1		c=100		c=10000	
Fiabilidad global (%)	71.8741	Fiabilidad global (%)	59.3029	Fiabilidad global (%)	59.2087
Precisión de sombras (%)	100.0000	Precisión de sombras (%)	100.0000	Precisión de sombras (%)	100.0000
<u>Random Forest</u>					
Max. depth of the tree = 50		Max. depth of the tree = 100		Max. depth of the tree = 150	
Fiabilidad global (%)	61.7646	Fiabilidad global (%)	68.1835	Fiabilidad global (%)	59.4776
Precisión de sombras (%)	99.9703	Precisión de sombras (%)	99.9205	Precisión de sombras (%)	99.9148

Fiabilidades global y precisiones de la clasificación de los edificios:

Iteración 1					
<u>KNN</u>					
k=5		k=30		k=100	
Fiabilidad global (%)	75.5798	Fiabilidad global (%)	75.5806	Fiabilidad global (%)	75.5288
Precisión de sombras (%)	72.1789	Precisión de sombras (%)	72.2039	Precisión de sombras (%)	72.1508
<u>SVM</u>					
c=1		c=100		c=10000	
Fiabilidad global (%)	74.4384	Fiabilidad global (%)	79.4646	Fiabilidad global (%)	78.5596
Precisión de sombras (%)	72.1894	Precisión de sombras (%)	77.5457	Precisión de sombras (%)	76.3529
<u>Random Forest</u>					
Max. depth of the tree = 50		Max. depth of the tree = 100		Max. depth of the tree = 150	
Fiabilidad global (%)	75.7018	Fiabilidad global (%)	75.3968	Fiabilidad global (%)	75.6589
Precisión de sombras (%)	71.8161	Precisión de sombras (%)	71.4273	Precisión de sombras (%)	71.7607

Iteración 2					
<u>KNN</u>					
k=5		k=30		k=100	
Fiabilidad global (%)	69.4905	Fiabilidad global (%)	69.4607	Fiabilidad global (%)	69.4601
Precisión de sombras (%)	66.5696	Precisión de sombras (%)	66.5414	Precisión de sombras (%)	66.5462
<u>SVM</u>					
c=1		c=100		c=10000	
Fiabilidad global (%)	62.8756	Fiabilidad global (%)	70.4219	Fiabilidad global (%)	68.3382
Precisión de sombras (%)	60.3640	Precisión de sombras (%)	66.8708	Precisión de sombras (%)	64.6066
<u>Random Forest</u>					
Max. depth of the tree = 50		Max. depth of the tree = 100		Max. depth of the tree = 150	
Fiabilidad global (%)	67.9030	Fiabilidad global (%)	64.8369	Fiabilidad global (%)	64.6207
Precisión de sombras (%)	64.4993	Precisión de sombras (%)	61.4156	Precisión de sombras (%)	61.2916

Iteración 3					
<u>KNN</u>					
k=5		k=30		k=100	
Fiabilidad global (%)	74.3927	Fiabilidad global (%)	74.2776	Fiabilidad global (%)	74.3970
Precisión de sombras (%)	78.7974	Precisión de sombras (%)	78.7402	Precisión de sombras (%)	78.7937
<u>SVM</u>					
c=1		c=100		c=10000	
Fiabilidad global (%)	73.4117	Fiabilidad global (%)	77.7821	Fiabilidad global (%)	76.7990
Precisión de sombras (%)	80.0936	Precisión de sombras (%)	81.5039	Precisión de sombras (%)	80.9341
<u>Random Forest</u>					
Max. depth of the tree = 50		Max. depth of the tree = 100		Max. depth of the tree = 150	
Fiabilidad global (%)	72.6536	Fiabilidad global (%)	72.5872	Fiabilidad global (%)	72.5507
Precisión de sombras (%)	74.1635	Precisión de sombras (%)	74.1013	Precisión de sombras (%)	73.9693

