

# Trabajo Fin de Máster Ingeniería Aeronáutica

## **Detección de cambios en el terreno a partir de imágenes de UAV multitemporales**

Autor: Gabriel Piñero Ros

Tutores: Cristina Torrecillas Lozano

Antonio Miguel Pérez Romero

**Dpto. Ingeniería Gráfica  
Escuela Técnica Superior de Ingeniería  
Universidad de Sevilla**

Sevilla, 2024





Trabajo Fin de Máster  
Ingeniería Aeronáutica

# **Detección de cambios en el terreno a partir de imágenes de UAV multitemporales**

Autor:

Gabriel Piñero Ros

Tutores:

Cristina Torrecillas Lozano

Profesora titular

Antonio Miguel Pérez Romero

Profesor titular

Dpto. Ingeniería Gráfica  
Escuela Técnica Superior de Ingeniería  
Universidad de Sevilla

Sevilla, 2024



Trabajo Fin de Máster: Detección de cambios en el terreno a partir de imágenes de UAV multitemporales

Autor: Gabriel Piñero Ros

Tutores: Cristina Torrecillas Lozano  
Antonio Miguel Pérez Romero

El tribunal nombrado para juzgar el Proyecto arriba indicado, compuesto por los siguientes miembros:

Presidente:

Vocales:

Secretario:

acuerdan otorgarle la calificación de:

El Secretario del Tribunal

Fecha:



# Agradecimientos

---

Agradecer a mi familia el apoyo durante estos años de estudio.

También agradecer a la profesora Cristina Torrecillas Lozano y al profesor Antonio Miguel Pérez Romero su apoyo durante la realización de este proyecto.



# Resumen

---

Este proyecto desarrolla el uso de la fotogrametría para la obtención de modelos tridimensionales a partir de imágenes bidimensionales. Se centra en los usos cartográficos de esta disciplina, especialmente en la utilización de aeronaves pilotadas en remoto (RPA) para la toma de imágenes. También estudia la detección de cambios en el terreno a partir de imágenes multitemporales, aplicando algoritmos y técnicas de aprendizaje automatizado.

Los datos de partida fueron las ortofotos y modelos digitales de elevaciones de 2017, junto a las imágenes aéreas tomadas mediante RPA en 2022 en el pueblo sevillano de Lebrija, en una zona donde se conoce la existencia de subsidencia en el terreno. La realización del proceso fotogramétrico hasta obtener el modelo tridimensional, incluyendo la ortofotografía y el modelo digital de elevaciones (MDE) del territorio en 2022, ha sido realizada mediante el software comercial Agisoft Metashape®.

El análisis realizado para la detección de cambios en el terreno ha sido ejecutado mediante el software de Sistema de Información Geográfica, QGIS®, y han sido utilizadas secuencias de comandos en el lenguaje de programación Python y el complemento Semi-Automatic Classification Plugin, que contiene algoritmos de aprendizaje automatizado, para conseguir la identificación de patrones en las variaciones que se hayan producido en el lapso temporal de 5 años entre vuelos, y poder obtener una clasificación automática de los cambios que haya habido en el terreno.

En cuanto al levantamiento fotogramétrico, los resultados muestran el modelo tridimensional del terreno junto a su ortofoto y modelo digital de elevaciones, donde destacan su precisión y representación veraz del terreno en la realidad. Sobre la detección de variación en el terreno mediante la aplicación de aprendizaje automatizado, los resultados arrojan la obtención de patrones de cambio en las imágenes que pueden ser extrapolables a variaciones en el terreno, haciendo hincapié en las limitaciones del proceso si la cantidad de información espectral de las imágenes no es suficiente.



# Abstract

---

This project develops the use of photogrammetry to obtain three-dimensional models from two-dimensional images. It focuses on the cartographic uses of this discipline, especially in the use of remotely piloted aircraft (RPA) for image acquisition. It also studies the detection of terrain changes from multi-temporal imagery, applying algorithms and machine learning techniques.

The starting data were orthophotos and digital elevation models from 2017, together with aerial images taken by RPA in 2022 in the Sevillian town of Lebrija, in an area where the existence of subsidence in the terrain is known. The photogrammetric process to obtain the three-dimensional model, including orthophotography and the digital elevation model (DEM) of the territory in 2022, was carried out using the commercial software Agisoft Metashape®.

The analysis carried out for the detection of changes in the terrain has been executed using the Geographic Information System software, QGIS®, and scripts in the Python programming language and the Semi-Automatic Classification Plugin, which contains automated learning algorithms, have been used to identify patterns in the variations that have occurred in the time span of 5 years between flights, and to obtain an automatic classification of the changes that have occurred in the terrain.

Regarding the photogrammetric survey, the results show the three-dimensional terrain model together with its orthophoto and digital elevation model, highlighting its accuracy and true representation of the terrain in reality. Regarding the detection of terrain variation through the application of automated learning, the results show the obtaining of patterns of change in the images that can be extrapolated to terrain variations, emphasising the limitations of the process if the amount of spectral information in the images is not sufficient.



# Índice

---

<b>Agradecimientos</b>	<b>I</b>
<b>Resumen</b>	<b>III</b>
<b>Abstract</b>	<b>V</b>
<b>Índice</b>	<b>VII</b>
<b>Índice de Tablas</b>	<b>X</b>
<b>Índice de Figuras</b>	<b>XII</b>
<b>1 Introducción</b>	<b>1</b>
1.1 <i>La Fotogrametría</i>	1
1.1.1 Origen y contexto histórico	1
1.1.2 Definición y utilización	3
1.1.3 Fotogrametría aplicada a la Cartografía	6
1.2 <i>La Teledetección</i>	8
1.2.1 Definición y utilización	8
1.2.2 Proyecto PNOA-LiDAR	12
1.3 <i>El Aprendizaje automatizado</i>	14
1.3.1 Definición y conceptos generales	14
1.3.2 Algoritmos utilizados en ML	14
1.3.3 Utilización del ML	15
1.4 <i>Objetivo y finalidad del proyecto</i>	16
<b>2 Datos</b>	<b>18</b>
2.1 <i>Emplazamiento de la zona de estudio</i>	18
2.2 <i>Datos Vuelo 2017</i>	20
2.2.1 Especificaciones del RPA	21
2.2.2 Especificaciones de la cámara	22
2.2.3 Características del vuelo	23
2.3 <i>Datos Vuelo 2022</i>	24
2.3.1 Especificaciones del RPA	24
2.3.2 Especificaciones de la cámara	26
2.3.3 Características del vuelo	27
2.4 <i>Puntos de control</i>	30
2.5 <i>Especificaciones Hardware</i>	33
<b>3 Metodología</b>	<b>35</b>
3.1 <i>Especificaciones de Software</i>	35
3.2 <i>Levantamiento fotogramétrico en Agisoft Metashape®</i>	36
3.2.1 Carga y orientación de fotografías	38
3.2.2 Generación de nube de puntos densa	42
3.2.3 Generación de mallado	42

3.2.4	Generación de textura	43
3.2.5	Salida de datos. Generación de modelo digital de elevaciones, ortofotografía, e informe	44
3.3	<i>Detección de cambios superficiales en el terreno mediante ML</i>	45
3.3.1	Carga de datos y establecimiento de formato adecuado	46
3.3.2	Instalación de librerías y complementos	47
3.3.3	Creación de ráster de diferencias	48
3.3.4	Detección de cambios y salida de datos	50
<b>4</b>	<b>Resultados</b>	<b>53</b>
4.1	<i>Levantamiento fotogramétrico en Agisoft Metashape®</i>	53
4.2	<i>Detección de cambios superficiales en el terreno mediante ML</i>	65
4.2.1	Análisis según variación en bandas RGB	65
4.2.2	Detección de cambios mediante SCP	69
<b>5</b>	<b>Conclusiones</b>	<b>77</b>
<b>Anexo A</b>	Secuencia de Comandos ( <i>scripts</i> ) en Python	<b>80</b>
<b>Referencias</b>		<b>89</b>



# ÍNDICE DE TABLAS

---

Tabla 1-1: Comparativa de realización de vuelo fotogramétrico entre aeronave tripulada y remotamente tripulada [12].	8
Tabla 2-1: Comparativa de características entre los vuelos 2017 y 2022.	29
Tabla 2-2: Coordenadas Puntos de Control en Zona 1.	31
Tabla 2-3: Coordenadas Puntos de Control Zona 2.	32
Tabla 4-1: Características principales de la nube de puntos dispersa.	54
Tabla 4-2: Desglose de validez de Puntos de Control.	56
Tabla 4-3: Resultados obtenidos en error para los puntos de control en el proyecto.	57
Tabla 4-4: Características principales de la nube de puntos densa generada en Metashape®.	57
Tabla 4-5: Características del mallado generado en Metashape®.	59
Tabla 4-6: Características principales del MDE generado en Metashape®.	63
Tabla 4-7: Resolución y tamaño de ortofotos y MDE adaptados para realizar el apilamiento.	69
Tabla 4-8: Productos ráster obtenidos tras la diferencia de <i>stacks</i> .	70
Tabla 4-9: Parámetros elegidos en la realización del <i>clustering</i> en SCP.	71



# ÍNDICE DE FIGURAS

---

Figura 1-1: Representación gráfica de la forma de uso de una cámara lúcida [2].	2
Figura 1-2: Fototeodolito de Laussedat [3].	2
Figura 1-3: (Arriba) Foto obtenida mediante fototeodolito para la obtención de Mapa de París (Abajo).	3
Figura 1-4: Ejemplo de un levantamiento fotogramétrico para creación de modelo 3-D en una iglesia [5].	4
Figura 1-5: Reconstrucción utilizando fotogrametría en el Parque Arqueológico de Segóbriga [6].	5
Figura 1-6: Modelo 3-D de volcán y coladas tras la erupción del volcán de La Palma en 2021 [7].	5
Figura 1-7: Ejemplo esquemático de pasada para vuelo PNOA, donde se puede observar los solapes longitudinal y transversal [10].	7
Figura 1-8: Visualización de zona de estudio en Lebrija a través de ortofotografía PNOA 2022 [11].	7
Figura 1-9: Espectro electromagnético y rango visible para el ojo humano [14].	9
Figura 1-10: Porcentaje de reflexión por material según longitud de onda [14].	10
Figura 1-11: Ejemplo del uso de teledetección para detectar masas de agua [17].	10
Figura 1-12: Teledetección utilizando el índice de vegetación NVDI [18].	11
Figura 1-13: Imagen en canal infrarrojo tomada por satélite Sentinel sobre Pavia, Italia [19].	12
Figura 1-14: Ejemplo de MDT obtenido con PNOA-LiDAR [20].	13
Figura 1-15: Ejemplo de MDS obtenido con PNOA-LiDAR [20].	13
Figura 1-16: Ejemplo de Mapa LiDAR obtenido con PNOA-LiDAR [20].	13
Figura 1-17: Esquema de clasificación de datos siguiendo el algoritmo de <i>random forest</i> [23].	15
Figura 2-1: Ubicación de Lebrija en vista satelital [28].	18
Figura 2-2: Zonas de estudio alrededor del Castillo-Fortaleza de Lebrija [27].	19
Figura 2-3: Ortofotografía de las Zonas 1 (parte superior) y 2 (parte inferior) obtenidas con las imágenes del vuelo de 2017 [27].	20
Figura 2-4: Modelo Digital de Elevaciones de las Zonas 1 (parte superior) y 2 (parte inferior) obtenidas con las imágenes del vuelo de 2017 [27].	20
Figura 2-5: Dron DJI Phantom 4 en fase de vuelo [32].	21
Figura 2-6: Sistema de detección de obstáculos en DJI Phantom 4 [33].	22
Figura 2-7: Sistema <i>Gimbal</i> instalado en el dron DJI Phantom 4 [33].	22
Figura 2-8: Ejemplo de planificación de vuelo en rejilla simple (izquierda) y doble (derecha) en Pix4DCapture [34].	23
Figura 2-9: Explicación esquemática de solapamiento en vuelo dron [35].	23

Figura 2-10: Dron DJI Phantom 4 Pro en fase de vuelo [37].	25
Figura 2-11: Sistema de detección de obstáculos en DJI Phantom 4 Pro [39].	26
Figura 2-12: Dos imágenes tomadas por el dron secuencialmente.	28
Figura 2-13: Imagen tomada por el dron en la zona 1 de estudio.	29
Figura 2-14: Puntos de control sobre Zona 1 de estudio.	30
Figura 2-15: Puntos de control sobre Zona 2 de estudio.	31
Figura 3-1: Diagrama de flujo del proceso seguido en Metashape®.	37
Figura 3-2: Interfaz de flujo de trabajo en Metashape®.	37
Figura 3-3: Interfaz para nuevo proyecto en Metashape®.	38
Figura 3-4: Muestra de fotografías donde se aprecia un solape longitudinal (arriba) y transversal (abajo) apropiado.	39
Figura 3-5: Menú desplegado al proceder a la orientación de fotografías en Metashape®.	40
Figura 3-6: Elección del sistema de referencia deseado en Metashape®.	40
Figura 3-7: Formato de introducción de PC.	41
Figura 3-8: Ejemplo de elemento móvil (persona) cubierto con máscara en Metashape®.	41
Figura 3-9: Interfaz de creación de nube de puntos densa en Metashape®.	42
Figura 3-10: Interfaz de creación de malla en Metashape®.	43
Figura 3-11: Interfaz de creación de textura en Metashape®.	43
Figura 3-12: Interfaz de creación de ortofotografía en Metashape®.	44
Figura 3-13: Diagrama de flujo seguido en proceso de detección de cambios.	45
Figura 3-14: Captura de QGIS® donde se aprecian las capas cargadas y la ortofoto de la Zona 1 de 2017 superpuesta a la ortofoto del modelo completo de 2022.	46
Figura 3-15: Interfaz de creación de <i>shape</i> en QGIS®.	47
Figura 3-16: Instalación de librería para Python para QGIS®.	47
Figura 3-17: Interfaz de instalación de complementos para QGIS®.	48
Figura 3-18: Ejemplo de uso de calculadora ráster de QGIS®.	49
Figura 3-19: Interfaz de uso de SPC para QGIS®.	50
Figura 3-20: Interfaz de uso de algoritmo de <i>clustering</i> en SCP para QGIS®.	51
Figura 4-1: Muestra de fotografías cargadas en interfaz de Metashape®.	53
Figura 4-2: Nube de puntos dispersa generada en la Zona 1 de estudio en Metashape®.	54
Figura 4-3: Nube de puntos dispersa generada en la Zona 2 de estudio en Metashape®.	54
Figura 4-4: Primera aproximación de PC9 y PC10 realizada por Metashape® al cargar las coordenadas de los PC.	55
Figura 4-5: Punto de control 36 (Zona 1) rechazado debido a imposibilidad de encontrarlo en las imágenes aéreas.	56
Figura 4-6: Proyección de PC válida (izquierda) en comparación proyección no válida del mismo PC por falta de visibilidad (derecha). Metashape®.	56
Figura 4-7: Nube de puntos dispersos y proyección de puntos de control en Metashape®.	57
Figura 4-8: Nube de puntos densa generada en la Zona 1 en Metashape®.	58
Figura 4-9: Nube de puntos densa generada en la Zona 2 en Metashape®.	58

Figura 4-10: Mallado obtenido en la Zona 1 de estudio en Metashape®.	59
Figura 4-11: Mallado obtenido en la Zona 2 de estudio en Metashape®.	60
Figura 4-12: Texturizado obtenido en la Zona 1 de estudio en Metashape®.	60
Figura 4-13: Texturizado obtenido en la Zona 2 de estudio en Metashape®.	61
Figura 4-14: Comparativa de representación de vegetación alta en modelo texturizado (arriba) con respecto a modelo mallado (abajo) generados en Metashape®.	61
Figura 4-15: Comparativa de representación de vegetación baja en modelo texturizado (arriba) con respecto a modelo mallado (abajo) generados en Metashape®.	62
Figura 4-16: Comparativa de representación de zonas rocosas en modelo texturizado (arriba) con respecto a modelo mallado (abajo) generados en Metashape®.	62
Figura 4-17: Comparativa de representación de una edificación en modelo texturizado (arriba) con respecto a modelo mallado (abajo) generados en Metashape®.	63
Figura 4-18: Modelo Digital de Elevaciones generado para la zona de estudio al completo obtenido en Metashape®.	63
Figura 4-19: Ortofotografía de la zona de estudio al completo obtenida en Metashape®.	64
Figura 4-20: Ráster de diferencias obtenido mediante <i>script</i> de Python para QGIS® para las zonas 1 (arriba) y 2 (abajo).	66
Figura 4-21: Histograma obtenido en el ráster de diferencias en QGIS®.	66
Figura 4-22: Clasificación realizada en ráster de diferencias.	67
Figura 4-23: Fragmento de ráster de diferencias (arriba), orto 2017 (medio) y orto 2022 (abajo) para la Zona 1.	68
Figura 4-24: Fragmento de ráster de diferencias (arriba), orto 2017 (abajo izquierda) y orto 2022 (abajo derecha) para la Zona 2.	69
Figura 4-25: Carga de bandas en SCP.	70
Figura 4-26: Generación de clasificación tipo <i>clustering</i> en SCP.	71
Figura 4-27: <i>Clustering</i> obtenido para la Zona 1, sin filtrar (arriba), filtrado (medio) y leyenda de colores (abajo).	72
Figura 4-28: <i>Clustering</i> obtenido para la Zona 2, sin filtrar (arriba), filtrado (medio) y leyenda de colores (abajo).	73
Figura 4-29: Zona 1. Fragmento de <i>clustering</i> (arriba), ortofoto 2017 (abajo izq.) y ortofoto 2022 (abajo dcha.).	74
Figura 4-30: Zona 2. Fragmento de <i>clustering</i> (arriba), ortofoto 2017 (abajo izq.) y ortofoto 2022 (abajo dcha.).	74



# 1 INTRODUCCIÓN

---

En este apartado introductorio, se detallarán pues los principios fundamentales de la fotogrametría, de la teledetección y del ML, así como su estado de desarrollo en la actualidad y las principales aplicaciones relacionadas con nuestro campo de estudio, para acabar con el objetivo del proyecto presentado.

## 1.1 La Fotogrametría

### 1.1.1 Origen y contexto histórico

Aunque se tiene constancia de influencias previas, el origen de esta disciplina se encuentra estrechamente ligado al ingeniero y militar francés Aimé Laussedat (1819-1907). Se le conoce como el “Padre de la Fotogrametría” debido principalmente a sus investigaciones sobre el uso de la fotografía para realizar mapas topográficos (Metrofotografía) [1].

Su interés se basaba en buscar un conjunto de métodos sencillos para poder utilizarlos fácilmente en su entorno de trabajo, el militar, y que todo el ejército pudiera aplicar. En sus comienzos, utilizó la cámara lúcida para poder dibujar manualmente los paisajes. La cámara lúcida es un dispositivo que sirve para realizar una superposición óptica del tema que se quiere dibujar sobre la superficie sobre la que se quiere dibujar (ver Figura 1-1). Posteriormente, comenzó a utilizar la cámara fotográfica, sobre todo tras las mejoras en los objetivos y la corrección de las deformaciones de éstos.

En cuanto al trazo de vistas en perspectiva, se requería gran capacidad de visión espacial y conocimientos técnicos que, aunque él tenía, no se encontraban presentes en sus compañeros de ejército, por lo que sustituyó esta necesidad de habilidades especiales por el uso de cámaras lúcidas, previamente al uso del telémetro (sistema que permite fijar una posición de vista e incorpora un telescopio), instrumento que él mismo ayudó a desarrollar.

Finalmente, cuando los avances en fotografía ya fueron más notables, su principal método de trabajo se basaba en el uso de realizar fotografías terrestres mediante un instrumento llamado fototeodolito, combinación de teodolito y cámara (ver Figura 1-2). Este instrumento fue desarrollado junto a un equipo de militares cuando el ejército francés les dotó de un daguerrotipo, el instrumento más primitivo utilizado en la toma de fotografías.

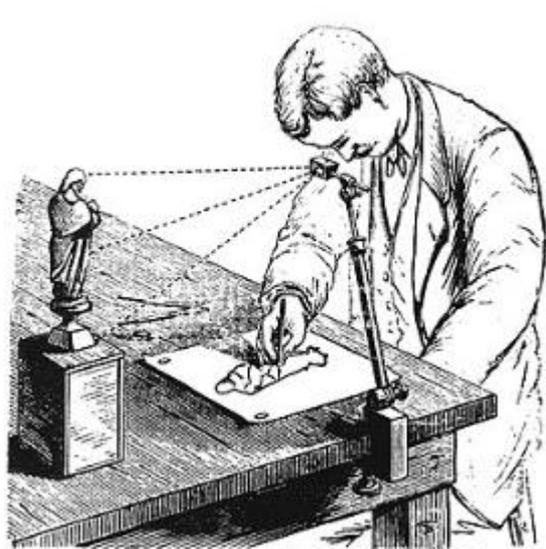


Figura 1-1: Representación gráfica de la forma de uso de una cámara lúcida [2].



Figura 1-2: Fototeodolito de Laussedat [3].

Uno de los principales logros de Aimé Laussedat fue su participación en 1858 en una nueva triangulación geodésica que se hizo de España. Estas triangulaciones tenían por objetivo establecer vértices geodésicos por todo el territorio español dotándolos de coordenadas geográficas. Junto a la compañía Brunner, desarrolló un dispositivo de medición de latitud y longitud tremendamente preciso para la época [3].

El hito más importante de su carrera se dio en 1861, cuando realizó el experimento de Buc (ver Figura 1-3), donde obtuvo un mapa de una zona de París mediante metrofotografía, lo que hizo que el ejército francés le destinara recursos concretos para que siguiera desarrollando la técnica.

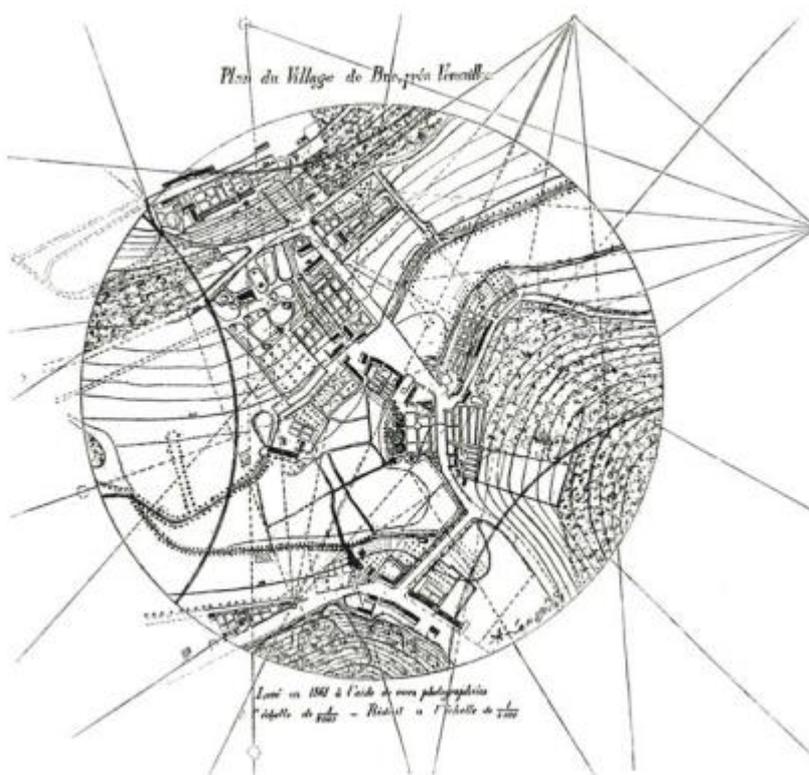
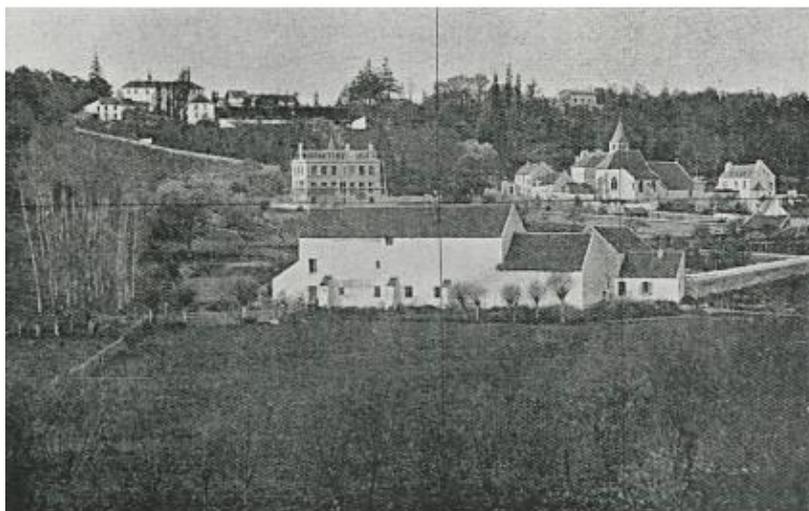


Figura 1-3: (Arriba) Foto obtenida mediante fototeodolito para la obtención de Mapa de París (Abajo).

### 1.1.2 Definición y utilización

Una vez se tiene un contexto de los orígenes de la fotogrametría, se pasa a conocer el estado actual de la tecnología con algunas definiciones de épocas más modernas.

Según la Sociedad Americana de Fotogrametría y Teledetección, “*la fotogrametría es el arte, ciencia y tecnología para la obtención de medidas fiables de objetos físicos y su entorno, a través de grabación, medida e interpretación de imágenes y patrones de energía electromagnética radiante y otros fenómenos*” [4].

Dados los avances tecnológicos presentes hoy en día, ya es posible crear una reconstrucción de un objeto en tres dimensiones a partir de fotografías mediante el uso de software informático específico que emplean las ecuaciones de colinearidad para la resolución del sistema proyectivo. Además, es posible reconstruir también color y textura del objeto de estudio mediante el uso de dos tecnologías recientes: *Structure from Motion* y *Multi-View Stereo*.



Figura 1-4: Ejemplo de un levantamiento fotogramétrico para creación de modelo 3-D en una iglesia [5].

En esencia, para aplicar la técnica de fotogrametría, se necesita una cámara con la que tomar las fotografías y un dispositivo con pantalla y acceso a internet. Debido a la facilidad actual de tener ambas tecnologías y a su versatilidad, la fotogrametría presenta una gran variedad de disciplinas de uso donde se requiere precisión en la representación espacial, como por ejemplo en mapas o en estructuras. [26]:

- Topografía: Utilizada en el levantamiento y elaboración precisa de cartografía, facilitando la representación de los territorios. También se pueden crear modelos superficiales, modelos digitales de elevaciones y representaciones 3-D. Un punto favorable a su uso en este ámbito es la facilidad para la georreferenciación de los resultados a sistemas de referencia de coordenadas reglados.
- Infraestructuras: Utilizada en la detección de deterioro en estructuras tales como pavimentos, puentes, edificios, etc. Se puede hacer volar un dron alrededor de la infraestructura y tomar fotos con su cámara de alta resolución. Una vez se tengan las fotografías, se puede obtener un modelo tridimensional de la infraestructura y, aplicando inteligencia artificial de detección de cambios, entrenar un modelo para que detecte grietas, fisuras, ausencias de volumen, etc.
- Arqueología: La posibilidad de crear modelos y reconstrucciones 3-D mediante técnicas no invasivas y sin riesgo de deterioro del patrimonio, es el mayor valor añadido que aporta la fotogrametría a la reconstrucción arqueológica. Los modelos creados se pueden utilizar para conocer estados anteriores de los elementos como para planificar tareas de restauración (ver Figura 1-5).



Figura 1-5: Reconstrucción utilizando fotogrametría en el Parque Arqueológico de Segóbriga [6].

- Minería: Se da un uso parecido al cartográfico, ya que su principal utilización es la creación de mapas aéreos que sirvan para identificar zonas ricas en determinados minerales. Ya que las fotografías contienen información multispectral, se pueden vincular dichos espectros por los emitidos por los minerales, dando lugar así a la diferenciación del terreno según su composición mineral. Otra utilidad es la monitorización de la explotación minera, pudiendo dar una estimación del material extraíble restante.

Su utilización es considerada primordial de cara a la planificación de explotaciones mineras, ya que sirve para establecer una planificación previa de explotación, generando ahorro en costes y tiempo.

- Geología: Utilizada en terrenos con riesgos geológicos tales como terremotos o volcanes. Analiza la evolución del terreno, pudiendo así prever futuros movimientos sísmicos o subsidencia en zonas volcánicas. Un ejemplo de ello es el modelo 3-D de las coladas de la erupción del volcán de La Palma, en el archipiélago de Islas Canarias, en España [7]. En 2021, dicho volcán entró en erupción. El Consejo Superior de Investigaciones Científicas elaboró mediante el vuelo de drones un modelo 3-D que sirvió para analizar las grietas y tubos lávicos para así poder establecer indicadores de potenciales futuras erupciones y establecer planes de contingencia y mitigación (ver Figura 1-6).

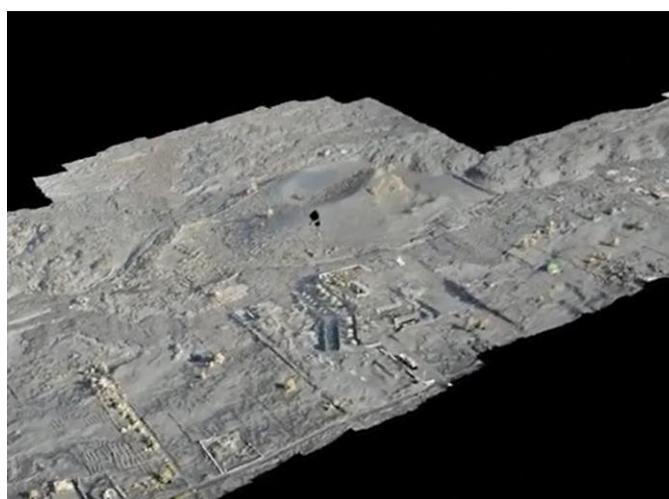


Figura 1-6: Modelo 3-D de volcán y coladas tras la erupción del volcán de La Palma en 2021 [7].

- Ciencias Ambientales. Permite la creación de modelos de vegetación. Estos modelos son útiles para analizar diferentes factores en zonas de interés o protegidas. Se puede analizar la frondosidad de los árboles, el crecimiento o decrecimiento de la vegetación, las zonas de erosión, la hidrología, etc.

Un uso muy común en España se da en el sector agrícola, ya que, mediante la toma de imágenes en cultivos, se pueden obtener modelos más eficientes de riego, monitorización de la salud de las plantaciones según su radiación, riego/fumigación teledirigida, etc.

Como se ha visto, la fotogrametría es ampliamente utilizada, a continuación, se muestran sus principales ventajas y desventajas.

### Ventajas:

- Relación precisión/precio favorable. Se pueden obtener modelos precisos a un bajo coste.
- Amplios rangos de análisis: edificios, cultivos, terrenos...
- Amplia gama de información, ya que las imágenes obtenidas son multiespectrales.
- Posibilidad de obtener modelos 3-D.
- Seguridad laboral en la toma de datos.

### Desventajas:

- Para proyectos complejos y que requieran altas precisión y calidad, ya se necesita una capacidad de toma de imágenes y procesamiento mayores, lo que aumenta considerablemente el precio.
- Restricciones en vuelos dron (altura, distancia de vuelo, imposibilidad de lanzamiento) según normativa Organización de Aviación Civil Internacional (OACI) [8].

### **1.1.3 Fotogrametría aplicada a la Cartografía**

Según el Instituto Geográfico Nacional (IGN) se define la fotogrametría como la técnica que tiene el fin de estudiar y definir con precisión la forma, dimensiones y posición en el espacio de un objeto cualquiera, utilizando medidas tomadas sobre fotografías de ese objeto [9].

Dentro del IGN, la fotogrametría comprende la fotografía aérea y la obtención de Modelos Digitales de Elevaciones (MDE), que posteriormente son utilizados para trazar la cartografía nacional. Además, también se procesan los datos obtenidos sobre la información geográfica general para que posteriormente puedan ser utilizados por el Instituto Nacional de Estadística para conocer el porcentaje de ocupación de suelo, la distinción del suelo construido versus el suelo vegetal, la hidrología, etc. Además, pueden ser utilizados por toda la población ya que son datos de dominio público.

El mayor proyecto fotogramétrico vigente en España es el Plan Nacional de Ortofotografía Aérea (PNOA), que tiene como objetivo la obtención de ortofotografías digitales con una resolución media de 25 cm sobre la mayor parte de la cobertura de la superficie de España. La dirección del proyecto pertenece al actual Ministerio de Transportes y Movilidad Sostenible, a través de la Dirección General del Instituto Geográfico Nacional [10].

El periodo de actualización está establecido actualmente en 3 años y se realiza cada año en zonas distintas. Los datos obtenidos son tratados rigurosamente y, dado que se trata de un proyecto colaborativo entre todas las Administraciones Públicas, siguiendo unas directrices concretas.

El vuelo para la obtención de las imágenes para el PNOA se realiza mediante una aeronave tripulada. Las fotografías tomadas tienen una orientación vertical y se exige que tengan un solapamiento entre ellas tanto en la dirección del avance de vuelo (mínimo 60%) como en las pasadas adyacentes (mínimo 30%), con ello se consigue superposición entre los fotogramas y la generación de puntos comunes que servirán de apoyo para generar la ortofotografía (ver Figura 1-7). La configuración de las pasadas de la trayectoria normalmente es

Este-Oeste.

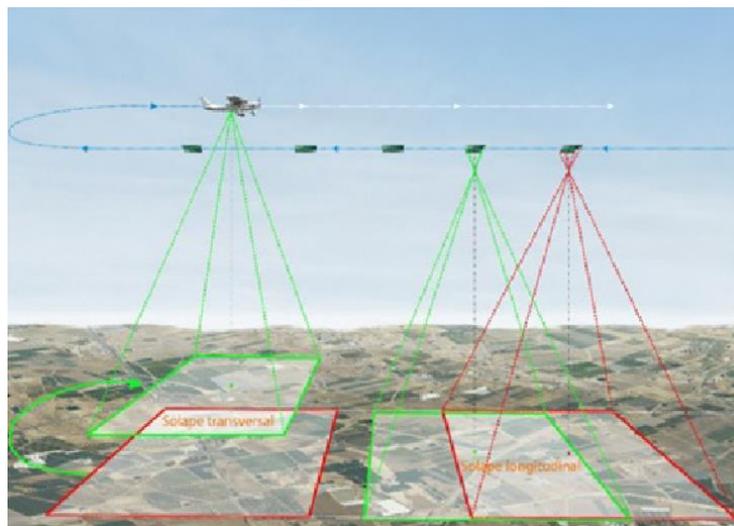


Figura 1-7: Ejemplo esquemático de pasada para vuelo PNOA, donde se puede observar los solapes longitudinal y transversal [10].



Figura 1-8: Visualización de zona de estudio en Lebrija a través de ortofotografía PNOA 2022 [11].

El uso de drones para fines cartográficos es una de las vías que más está siendo desarrollada en los últimos años, limitándose su idoneidad a áreas de trabajo de máximo  $10 \text{ km}^2$  [12]. Mediante el uso de cámaras de alta resolución instaladas en las aeronaves no tripuladas, se pueden obtener imágenes de alta calidad y precisión que posteriormente serán procesadas con software fotogramétrico, consiguiendo así la obtención de modelado tridimensional de terrenos, ortofotografías, altimetrías y georreferenciación precisa entre otros productos. El uso de drones proporciona una gran versatilidad a la hora de realizar los estudios, ya que tanto la planificación del vuelo como la accesibilidad a los lugares de interés son más sencillos en comparación al uso de aeronaves

tripuladas o imágenes satelitales, principales alternativas. Además, el coste de uso de drones es sustancialmente inferior, tanto por el precio del aparato como porque no es estrictamente necesaria la contratación de un piloto.

Tabla 1-1: Comparativa de realización de vuelo fotogramétrico entre aeronave tripulada y remotamente tripulada [12].

Características	Aeronave Tripulada	Aeronave Remotamente tripulada
Proyectos < 10 km <sup>2</sup>	No	Sí
Proyectos > 10 km <sup>2</sup>	Sí	No
Impacto del clima	Bajo	Alto
Movilidad en espacios pequeños	Baja	Muy alta
Capacidad de sensores	Muy alta	Alta
Riesgo operacional	Alto	Bajo
Calidad de imagen	Alta	Alta
Resolución de imagen	Media	Muy alta
GSD medio	7.5-15 cm/píxel	0.5/2 cm/píxel
Repetibilidad del vuelo	Baja	Muy alta
Coste operacional	Alto	Bajo

## 1.2 La Teledetección

### 1.2.1 Definición y utilización

En 1972, Estados Unidos lanzó el primer satélite de observación de la Tierra [13], dando lugar al comienzo de la utilización de técnicas de teledetección. En esa época, el coste computacional y económico de trabajar con imágenes satelitales hacían más complicado trabajar con esta técnica. En la actualidad, el desarrollo de la tecnología ha conllevado a que la obtención remota de datos a través de sensores esté a la orden del día.

La teledetección es la técnica avanzada de obtención de información sobre un objeto desde una distancia [14]. La toma de datos se realiza mediante la interacción electromagnética entre el terreno y el sensor. Focalizando en el campo de estudio de nuestro proyecto, la superficie de la que se obtendrán los datos será la superficie de la Tierra.

El principio de funcionamiento de la teledetección se basa en la recepción por parte de la Tierra de radiación electromagnética procedente del Sol. Esta radiación, es en parte absorbida, reflejada y emitida por la superficie de la Tierra cuando al recibe. La medición de esta radiación electromagnética reflejada o emitida mediante el uso de sensores, es lo conocido como teledetección. Estos sensores, pueden ir instalados en satélites, en aeronaves tripuladas, en drones, en lugares fijados a Tierra, etc.

La radiación electromagnética está constituida por diferentes frecuencias de ondas que forman el conjunto de todas las frecuencias del espectro electromagnético (ver Figura 1-9). Para el ojo humano, la mayor parte del espectro electromagnético no es visible. Por ello, se utilizan sensores como los infrarrojos, los ultravioleta, etc., para obtener la información y posteriormente procesarla.

La teledetección se puede clasificar según la tipología de sensor utilizada [15]:

- Teledetección Activa: El sensor cuenta con su propia fuente de emisión de radiación hacia la superficie del objeto y mide la respuesta en forma de radiación reflejada de vuelta. Su principal ventaja es su invariabilidad ante condiciones climatológicas adversas ya que suelen hacer uso de microondas. Su principal uso se da para medir distancias, alturas y condiciones atmosféricas. Algunos ejemplos de teledetección activa son:

- Rádar: Mide la dispersión que se produce en la señal emitida para así determinar la distancia al objeto.
  - LiDAR (*Light Detection and Ranging*): Realiza una emisión de impulsos luminosos para hallar la distancia al objeto según la cantidad de energía recuperada.
- Teledetección Pasiva: El sensor no emite radiación propia, sino que depende de los rayos solares que alcanzan el objetivo. Su principal desventaja es que se deben dar unas condiciones meteorológicas favorables para que la luz solar alcance la superficie de estudio.

La teledetección pasiva utiliza sensores multispectrales que miden la cantidad de radiación recibida con múltiples combinaciones de bandas. Dichas bandas pueden estar dentro del espectro visible para el ojo humano o fuera de éste como por ejemplo los infrarrojos o las microondas. Algunos ejemplos de teledetección pasiva son:

- Espectrómetro: Realiza distinciones y análisis en las bandas espectrales.
- Radiómetro: Determina la potencia de la radiación recibida por parte del objeto.

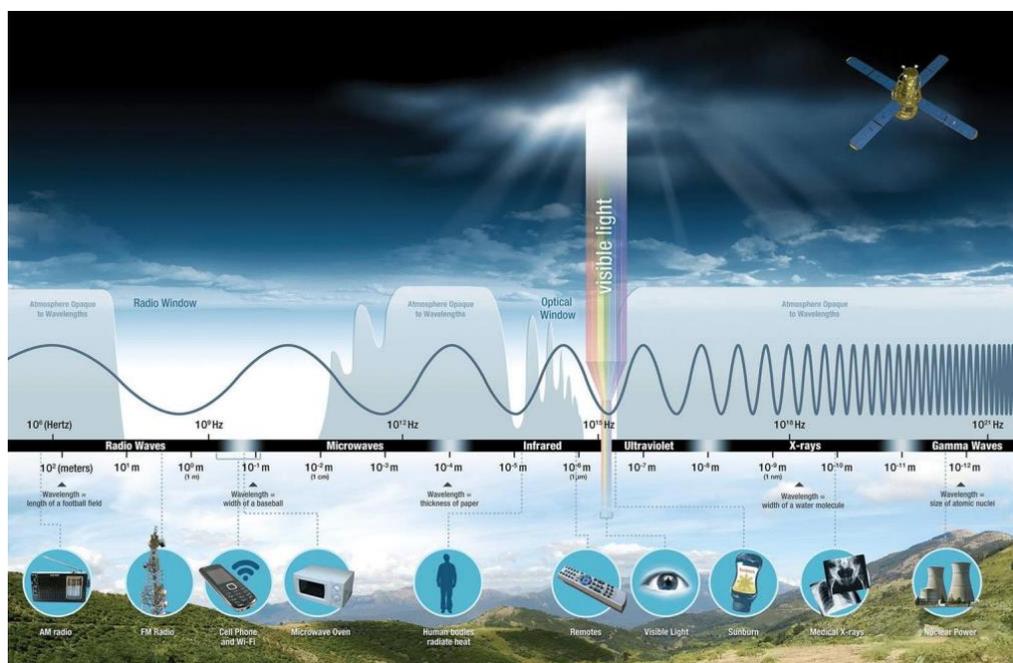


Figura 1-9: Espectro electromagnético y rango visible para el ojo humano [14].

Dependiendo del tipo de material del que esté compuesta una superficie, la absorción, emisión o reflexión de las ondas será de diferentes longitudes. El estudio de estas longitudes da lugar a poder identificar materiales a través de las longitudes de onda detectadas. Esta distinción es conocida como firma espectral de un material. En la Figura 1-10 se puede observar una gráfica que indica el porcentaje de reflexión dependiendo de la longitud de onda para diferentes materiales.

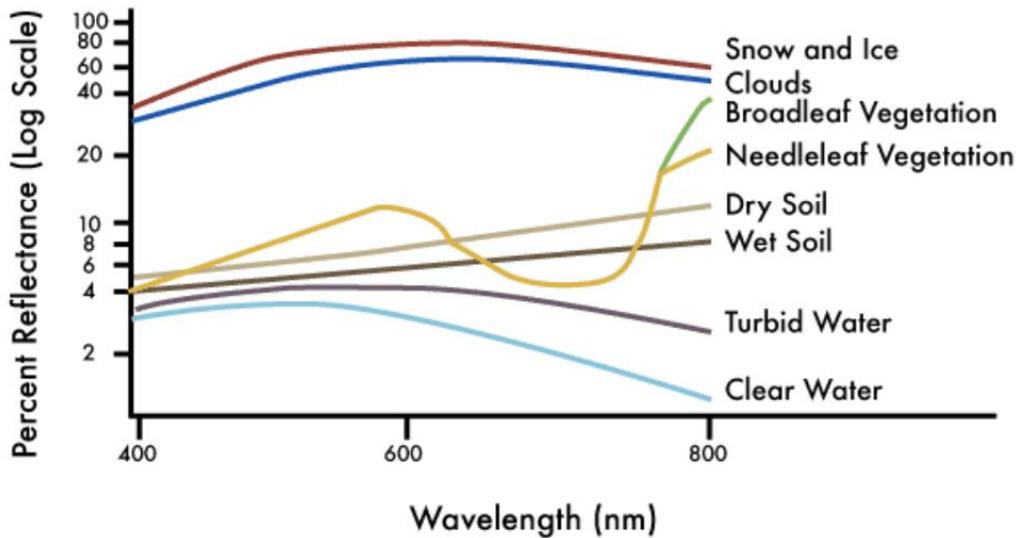


Figura 1-10: Porcentaje de reflexión por material según longitud de onda [14].

La teledetección tiene una gran aplicabilidad en diversos campos relacionados con el medio ambiente como la ecología, la agricultura, la meteorología, la cartografía, etc., donde es una herramienta muy útil debido a su capacidad de obtener información no visible para el ojo humano. A continuación, se muestran algunos usos de la teledetección para este tipo de fines [16]:

- Detección de agua en diversos ámbitos: consumo en agricultura, control de humedad en cultivos, seguimiento de inundaciones, control de la calidad superficial del agua para detectar contaminaciones, etc. El principio de funcionamiento de la detección de agua se basa en la absorción de longitudes de onda largas como las verdes y las rojas y de la radiación infrarroja por el contrario de la no absorción de las longitudes cortas (azules). Por ello, el agua se suele ver de color azul, como se muestra en la Figura 1-11.

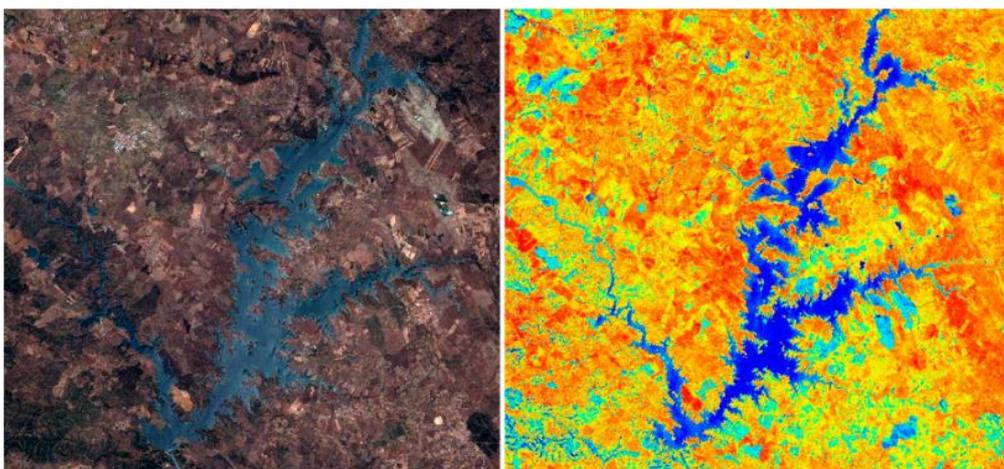


Figura 1-11: Ejemplo del uso de teledetección para detectar masas de agua [17].

- Estudios sobre la vegetación: variación de tipo de vegetación, de condiciones de humedad, monitorización de salud, inventarios forestales, etc.

La vegetación absorbe principalmente la luz visible roja, por lo que el ojo humano la percibe como

verde. Dependiendo de la manera en que se refleje la radiación, se pueden establecer patrones que permitan conocer el estado de salud y la frondosidad de las plantaciones. Algunas de las técnicas y estudios que se utilizan para ello son [18]:

- Índices de vegetación: Evalúan el estado de la vegetación comparando con bandas espectrales cercanas al rojo y al infrarrojo. Por ejemplo, el índice NVDI (Índice de Vegetación de Diferencia Normalizada) compara las bandas de infrarrojo y rojo para medir densidad y salud de la vegetación. Valores de NVDI superiores a 0.5 indican una buena salud de la vegetación.
- Detección de clorofila: Una alta concentración de clorofila en una planta implica una buena salud de la misma. La clorofila está relacionada con la absorción de los espectros rojos y azul, por lo que, monitorizar la concentración de clorofila a través de esta absorción indica el estado de salud de la planta.

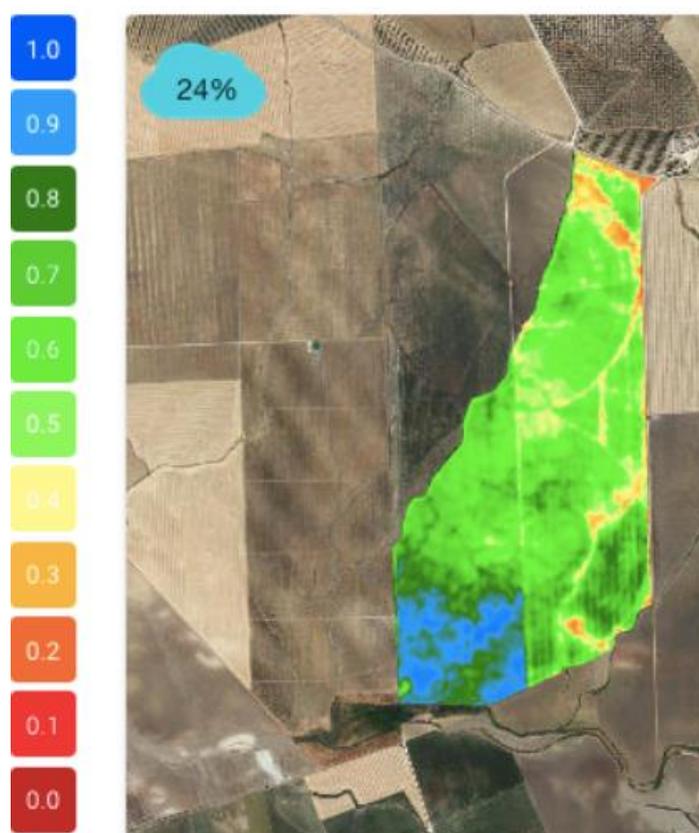


Figura 1-12: Teledetección utilizando el índice de vegetación NVDI [18].

- Monitorización de cambio climático: Un ejemplo de ello es el plan Copernicus [13], creado en 2001 como iniciativa conjunta de la Comisión Europea y de la Agencia Espacial Europea para la monitorización orientada a la mitigación de los efectos del cambio climático. Se trata de la recolección y tratamiento de datos por parte de 30 satélites. Su principal objetivo es el de generar una independencia europea a la hora de tomar medidas que puedan mitigar el cambio climático mediante información geográfica.

Los satélites pertenecientes al plan Copernicus son los llamados “*Sentinel*”. Las imágenes obtenidas son accesibles para toda la población y se encuentra categorizados según el tipo de imágenes que proporcionan:

- Sentinel-1: Imágenes rádar terrestres y oceánicas.
- Sentinel-2: Imágenes ópticas terrestres.

- Sentinel-3: Servicios globales de vigilancia terrestre y oceánica.



Figura 1-13: Imagen en canal infrarrojo tomada por satélite Sentinel sobre Pavia, Italia [19].

## 1.2.2 Proyecto PNOA-LiDAR

En el año 2009, se incorporó al proyecto del PNOA la técnica de teledetección LiDAR, que significa detección y medición de luz. El objetivo del proyecto es cubrir todo el territorio español mediante nubes de puntos de coordenadas x-y-z utilizando esta tecnología para tener un mapa orográfico completo del país. Este modelo orográfico es útil para analizar los potenciales desarrollos de modelos de negocio o de actividades en función de la idoneidad del terreno. También se utiliza para el análisis preventivo de catástrofes naturales y su posterior mitigación.

Desde su implantación, se han realizado 3 coberturas, plasmando su mejora en el aumento de la densidad mínima de puntos por metro cuadrado, que comenzó siendo de media 0.5 puntos/m<sup>2</sup> entre 2009 y 2015, para pasar a ser de 5 puntos/m<sup>2</sup> en 2022-actualidad. Otro punto a tener en cuenta es la georreferenciación, este modelo está referenciado al sistema ETRS89, husos 28, 29, 30 y 31 según la parte de España que se esté cubriendo.

Su modo de funcionamiento es el de un sensor activo, ya que emite pulsos de luz ininterrumpidamente y capta los retornos, comúnmente llamados “rebotes”. Con la medición del tiempo que tarda en regresar la luz, se puede calcular la distancia y así recopilar la información tridimensional de los elementos [20].

Algunos de los productos obtenidos de este proyecto, y los más relacionados con nuestro objetivo de estudio son los siguientes:

- Modelo Digital del Terreno (MDT): Es un modelo de elevaciones superficial que obvia los obstáculos tales como bosques o edificaciones (ver Figura 1-14).
- Modelo Digital de Superficies (MDS): Representa la superficie del terreno incluyendo edificaciones, bosques, etc. (ver Figura 1-15).
- Mapa LiDAR: Permite visualizar una nube de puntos en formato ráster (ver Figura 1-16).

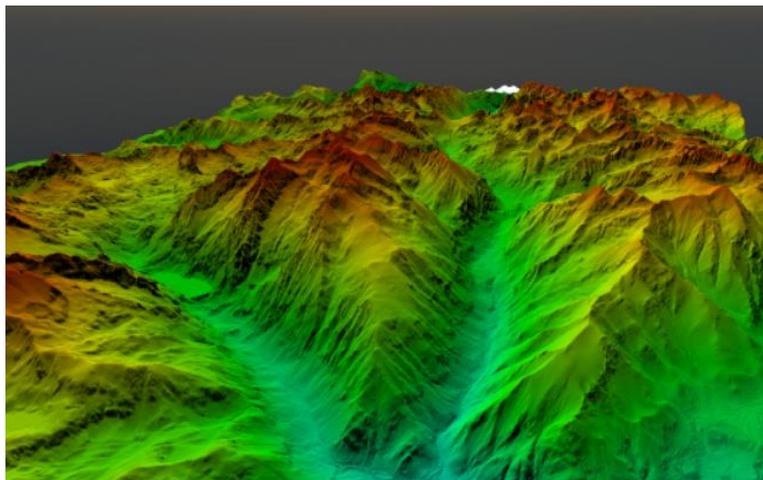


Figura 1-14: Ejemplo de MDT obtenido con PNOA-LiDAR [20].

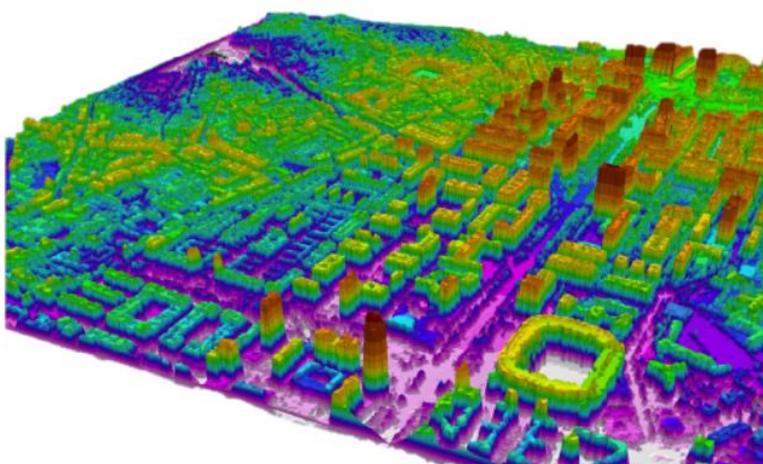


Figura 1-15: Ejemplo de MDS obtenido con PNOA-LiDAR [20].



Figura 1-16: Ejemplo de Mapa LiDAR obtenido con PNOA-LiDAR [20].

## 1.3 El Aprendizaje automatizado

### 1.3.1 Definición y conceptos generales

Se conoce como *Machine Learning (ML)* ó aprendizaje automático al conjunto de técnicas y algoritmos que dotan de capacidad a los sistemas de aprender e implementar mejoras de manera automática y en algunos casos autónoma a través de experiencias previas y realimentación de análisis de dichas experiencias [21]. Se engloba dentro de la disciplina de la inteligencia artificial y tuvo su aparición a principios de los años 1940.

El fundamento principal del ML se basa en la conversión de datos en información con la que nutrirse. Los algoritmos permiten a los sistemas tener la capacidad de identificar patrones en conjuntos de datos y lanzar predicciones. A mayor cantidad de datos, mayor capacidad de aprendizaje y de toma de decisiones, lo que da lugar a la mejora de los modelos y de sus predicciones.

La principal ventaja del ML es la infinitamente mayor capacidad de procesamiento que tienen los sistemas con respecto a los humanos. Con la aplicación de algoritmos sofisticados que permitan identificar patrones, el número millonario de iteraciones que es capaz de realizar una máquina le permite predecir tendencias de una forma mucho más precisa, incluso en tareas complejas. Además, el volumen de datos que pueden tratar es inabarcable para un humano por cuestiones de tiempo, destacando la eliminación de sesgos subjetivos.

Existen principalmente 2 tipos de modelos diferentes de ML, atendiendo a la autonomía del sistema para el aprendizaje [22]:

- Aprendizaje supervisado: Se entrena a la máquina introduciéndole conjuntos de datos clasificados para que los algoritmos encargados de clasificar posean muestras a modo de ejemplo y así ajustar el modelo a los parámetros deseados, evitando posibles desajustes debido a la tipología de los datos. Este tipo de aprendizaje es útil para ofrecer soluciones a problemas repetitivos.

Un ejemplo para este tipo de aprendizaje sería entrenar un modelo de mapeo de diferentes tipos de terreno (urbano, agrícola, forestal, acuático) para, creando previamente un conjunto de terrenos clasificados, ayudar al modelo a clasificar automáticamente las áreas registradas en las imágenes tomadas por un dron.

- Aprendizaje no supervisado: Estos modelos realizan clasificaciones en subconjuntos (clústeres) ante una entrada de datos no clasificados. Son útiles para detectar patrones ocultos o conjuntos de datos similares aprovechando la capacidad iterativa de los sistemas. También se utiliza para realizar un análisis preliminar de la cantidad de categorías diferentes que pueden agruparse de un conjunto de datos, para después pasar a un aprendizaje supervisado con una mayor cantidad de información inicial. Este método mixto es conocido como aprendizaje semi-supervisado.

Este tipo de aprendizaje es muy utilizado en el sector del *marketing* y de finanzas porque es capaz de detectar de forma automática patrones de consumo.

### 1.3.2 Algoritmos utilizados en ML

Dependiendo del fin de la utilización de ML para el análisis y procesamiento de un conjunto de datos, existen diferentes algoritmos. A continuación, se explican brevemente algunos de ellos:

- Redes neuronales: Posee un nivel muy alto de complejidad ya que simula el funcionamiento del cerebro humano, lo que implica un alto número de nodos análogos a las neuronas del cerebro.
- Agrupaciones o *Clustering*: Es un algoritmo de aprendizaje no supervisado. Agrupa datos similares en subconjuntos intentando que sean lo más similares entre sí dentro de cada uno de ellos.
- Bosque aleatorio o *Random forest*: Es un algoritmo de aprendizaje supervisado. El algoritmo genera árboles de decisión escogiendo datos aleatoriamente del conjunto de datos de entrada. Para que los árboles no sean similares entre sí, para cada nodo de cada árbol se selecciona aleatoriamente un subconjunto de características. Conforme el número de árboles va siendo mayor, se genera un modelo que reduce la varianza de los resultados, mejorando la precisión del modelo. Cada vez que entra un dato, pasa por todos los árboles y es clasificado, una vez se tiene la decisión obtenida por cada árbol,

el dato de entrada es clasificado según la tipología más repetida de las decisiones de los árboles.

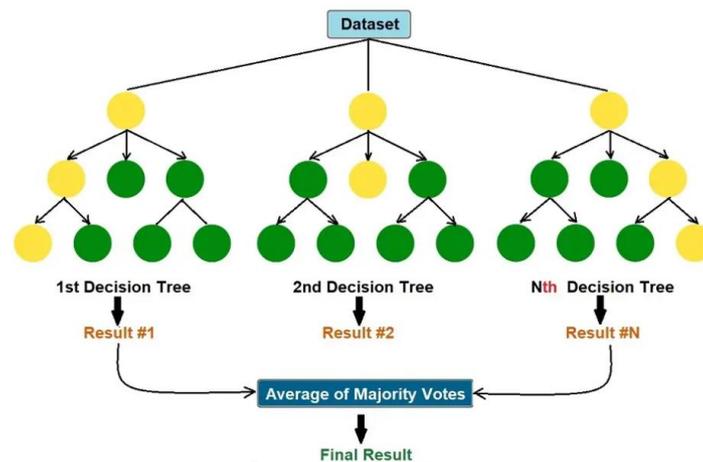


Figura 1-17: Esquema de clasificación de datos siguiendo el algoritmo de *random forest* [23].

### 1.3.3 Utilización del ML

Debido al avance de la tecnología a partir del año 2000, la capacidad de computación ha aumentado exponencialmente, lo que unido a la reducción del coste de los ordenadores ha conducido a un auge en la inteligencia artificial, incluyendo el *Machine Learning*.

La aplicación de algoritmos y técnicas de ML se da en una gran variedad de campos. A continuación, se presentan algunos de ellos:

- Sector Infraestructuras: Enfocado al mantenimiento predictivo y preventivo. Un ejemplo de ello se da en un proyecto llevado a cabo por investigadores de la Universidad Católica de Chile sobre la gestión de pavimentos asfálticos en la red secundaria de aeropuertos de Chile. Desarrollaron un modelo de inteligencia artificial que, junto a las imágenes y mediciones automatizadas realizadas por drones, permitirá realizar la gestión de pavimentos de forma preventiva, aumentando la calidad de la infraestructura y reduciendo costes [25].
- Sector Salud: Se presenta como una solución para el lanzamiento de diagnósticos predictivos. Tras el análisis de los datos del paciente, también es capaz de predecir su respuesta ante un tratamiento determinado. Por otro lado, dado el gran volumen de datos con el que pueden trabajar, se utiliza el ML para la prevención de enfermedades genéticas/hereditarias tras un análisis genómico del paciente [24].
- Sector Finanzas: Se utilizan principalmente para detectar patrones de consumo y patrones anómalos en transferencias financieras (detección de fraude).
- Logística y transporte: Consiguen reducción de tiempos de ruta por la predicción de exceso de tráfico, eligiendo la ruta más eficiente.
- Agricultura y medio ambiente: Monitorización del rendimiento de cultivos, prevención y detección de plagas y enfermedades, estudios de humedad del terreno y de la vegetación, optimización de uso de fertilizantes dependiendo de la salud de la planta, análisis de fotos tomadas en diferentes momentos temporales para detección de cambios, etc.

## 1.4 Objetivo y finalidad del proyecto

Este Proyecto Fin de Máster (TFM) desarrolla un análisis de detección de cambios superficiales de un terreno delimitado aplicando técnicas de teledetección (en inglés *Remote Sensing*), tras la realización de un levantamiento fotogramétrico previo basado en la toma de fotografías aéreas mediante el vuelo de un dron.

Su desarrollo se puede dividir en dos partes bien diferenciadas:

- Resolución de un levantamiento **Fotogramétrico** mediante el procesamiento de fotografías tomadas por una Aeronave Remotamente Pilotada (en inglés, Remotely Piloted Aircraft -RPA-). Dicho procesamiento se llevará a cabo mediante el software comercial Metashape®, perteneciente a la empresa localizada en San Petesburgo, Agisoft.
- Aplicación de **Teledetección** y de técnicas de aprendizaje automático, más conocido como **Machine Learning (ML)** para conseguir un modelo de detección automática de cambios superficiales en el terreno entre imágenes con variación temporal.



## 2 DATOS

Una vez desarrollados los principales objetivos y marcos teóricos del proyecto, se puede continuar hacia la explicación detallada de los datos de entrada.

Estos se basan en dos vuelos realizados por dron sobre el mismo lugar, la localidad andaluza de Lebrija, con una diferencia temporal de 5 años. Del primer vuelo, en 2017, se tiene el resultado obtenido en el software Agisoft Metashape de la ortofotografía y el modelo digital de elevaciones, que servirán como punto de partida para la detección de cambios sobre el terreno con respecto al segundo vuelo. De dicho segundo vuelo, realizado en 2022, se tiene el conjunto de fotografías que habrá que procesar en Metashape para obtener las correspondientes ortofotografía y modelo digital de elevaciones.

### 2.1. Emplazamiento de la zona de estudio

La zona de estudio se encuentra en la localidad de Lebrija, perteneciente a la Comunidad Autónoma de Andalucía, dentro de la provincia de Sevilla y situada al sur de la península ibérica. Se encuentra dentro de la denominada zona como Bajo Guadalquivir, debido a su cercanía a la desembocadura de dicho río en el océano Atlántico, por lo que también tiene zona de marismas.

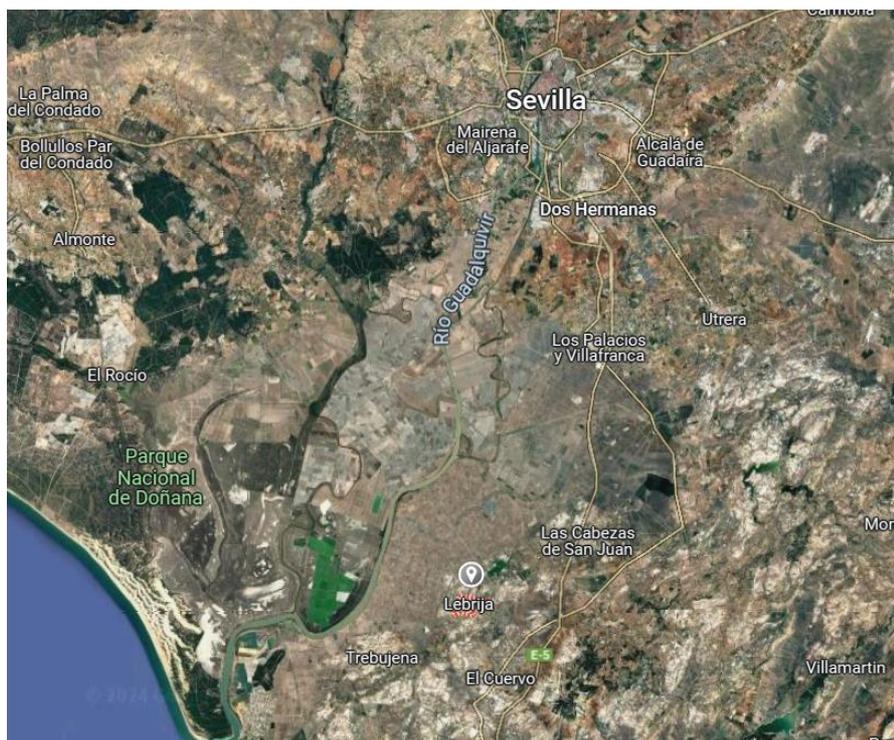


Figura 2-1: Ubicación de Lebrija en vista satelital [28].

Debido a su ubicación en la península ibérica, Lebrija presenta un clima mediterráneo con influencia del océano Atlántico, lo que deriva en inviernos con temperaturas mínimas en torno a los 5°C y sin gran presencia de precipitaciones, que se suelen concentrar en los meses de otoño e invierno, registrando unas precipitaciones de 150-200 litros por metro cuadrado anuales. La temporada de verano se presenta muy calurosa y seca con temperaturas que pueden alcanzar más de 40°C [29].

Su vegetación, debida principalmente a su clima y a las características de su emplazamiento, son cultivos agrícolas de hortalizas, verduras y cereales. Por otro lado, en zonas no cultivadas, aparecen de forma natural especies típicas de montaña mediterránea, con vegetación de matorrales como el lentisco y árboles como la encina o el pino [30].

La zona de estudio dentro de la localidad de Lebrija se encuentra en los alrededores del Castillo-Fortaleza, como se observa en la Figura 2-2. El análisis de la zona se va a subdividir en dos zonas, la Zona 1, en la parte superior derecha y la Zona 2, en la inferior izquierda. Estos vuelos se han hecho buscando variaciones de terreno pues se cree que hay mucho desprendimiento.



Figura 2-2: Zonas de estudio alrededor del Castillo-Fortaleza de Lebrija [27].

A continuación, se van a detallar las principales características de los vuelos de 2017 y 2022. Cabe destacar que se sobrevoló y se tomaron imágenes de exactamente la misma superficie.

## 2.2. Datos Vuelo 2017

El vuelo de 2017 es la entrada de datos inicial. De dicho vuelo, principalmente lo que se va a utilizar va a ser la Ortofotografía y el Modelo Digital de Elevaciones, presentados a continuación en las Figuras 2-3 y 2-4 respectivamente. Aun así, se va a realizar una comparativa de los aspectos principales de ambos vuelos para poder tener un contexto más amplio de las diferencias existentes entre ellos.



Figura 2-3: Ortofotografía de las Zonas 1 (parte superior) y 2 (parte inferior) obtenidas con las imágenes del vuelo de 2017 [27].

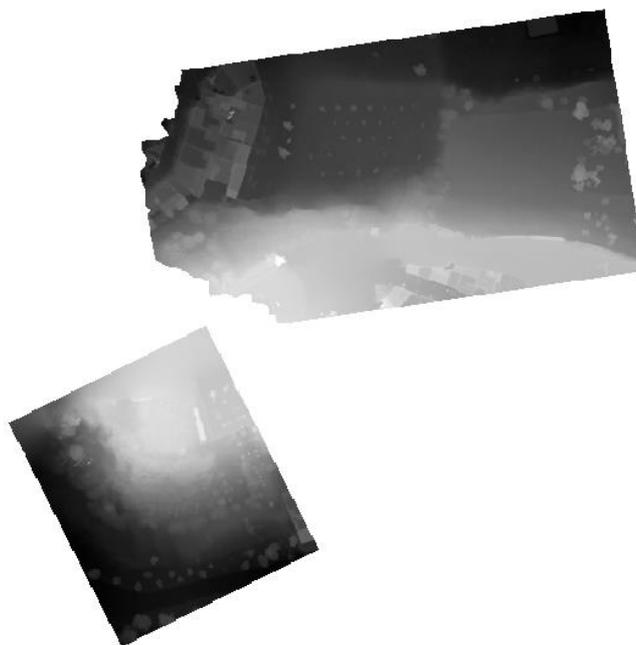


Figura 2-4: Modelo Digital de Elevaciones de las Zonas 1 (parte superior) y 2 (parte inferior) obtenidas con las imágenes del vuelo de 2017 [27].

### 2.2.1 Especificaciones del RPA

Para el vuelo de 2017 el RPA utilizado fue el Phantom 4 de la compañía china DJI. Se trata de un dron cuadricóptero con 4 rotores de gama media cuyo precio de salida rondaba los 1000\$. A continuación, se detallan sus principales características y las más influyentes sobre nuestro proyecto [31]:



Figura 2-5: Dron DJI Phantom 4 en fase de vuelo [32].

- Dimensiones y peso: Longitud Diagonal 350 mm (sin hélices) con 1380 gramos de peso.
- Autonomía de vuelo: 28 minutos.
- Velocidad ascenso máxima: 6 m/s.
- Velocidad descenso máxima: 4 m/s.
- Velocidad lineal máxima: 20 m/s.
- Altitud máxima: 6000 msnm.
- Detección de obstáculos: Sí, con evitado de colisiones mediante evasión, sobrevuelo o flotación. Rango 0.7 – 15 m. Utiliza un sistema de ultrasonidos y de datos por imagen para mantener la posición de la aeronave estable. La detección de obstáculos sólo existe para obstáculos que se encuentren de frente al dron, tal y como se muestra en la Figura 2-6.
- Estabilización de vuelo: Sí, 3 ejes (cabeceo, alabeo y guiñada).
- Posicionamiento por satélite: GPS / GLONASS.
- Frecuencia de radiocontrol: 2400 GHz – 2483 GHz.

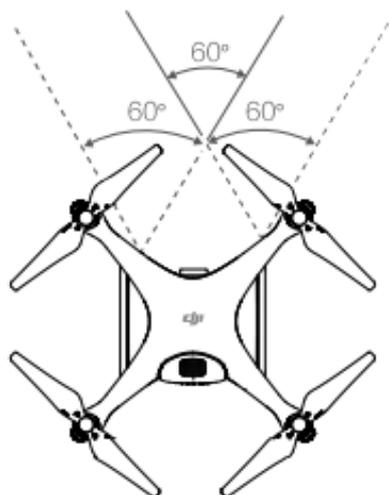


Figura 2-6: Sistema de detección de obstáculos en DJI Phantom 4 [33].

### 2.2.2 Especificaciones de la cámara

La cámara utilizada para realizar las fotografías en el DJI Phantom 4 es la Fc330 [27]. Como se puede observar en la Figura 2-7, va integrada en la parte inferior del dron y una de sus características más destacables es que cuenta con un sistema *Gimbal* (cardán), es decir, un sistema mecánico que permite unir dos ejes que no son coaxiales. Este sistema permite establecer un movimiento de rotación en la cámara que hará posible la toma de imágenes con diferentes ángulos. El ángulo de rotación de la cámara puede variar entre  $-90^\circ$  y  $+30^\circ$ , dando lugar a un rango de rotación efectiva de  $120^\circ$ .

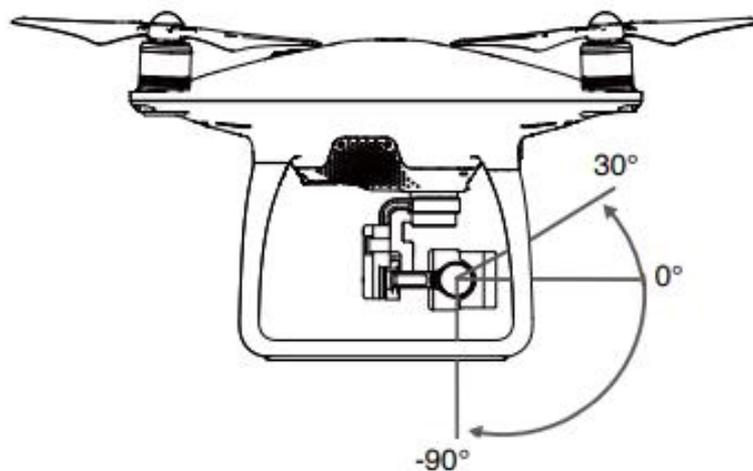


Figura 2-7: Sistema *Gimbal* instalado en el dron DJI Phantom 4 [33].

Se muestra a continuación el listado de características y especificaciones más relevantes de la cámara:

- Sensor 1/2.3" CMOS con 12.4 Megapíxeles efectivos.
- Objetivo FOV  $94^\circ$  20 mm (formato equivalente a 35 mm)  $f/2.8$  enfoque hacia infinito.
- Rango ISO 100-3200 para vídeo y 100-1600 para fotografía.
- Velocidad obturador electrónico 8 – 1/8000 s.

- Modos de fotografía: Disparo único, disparo en ráfaga 3/5/7, Timelapse y HDR para conseguir una mejor exposición en escenas muy brillantes u oscuras.
- Fotografía en JPEG y DNG con opción de añadir Micro SD de hasta 64 GB para almacenamiento.

### 2.2.3 Características del vuelo

El vuelo debe de ser planificado acorde a las necesidades del proyecto. Cabe destacar la existencia de software específico para programación de vuelos tales como Pix4DCapture® ó Drone Deploy®.



Figura 2-8: Ejemplo de planificación de vuelo en rejilla simple (izquierda) y doble (derecha) en Pix4DCapture [34].

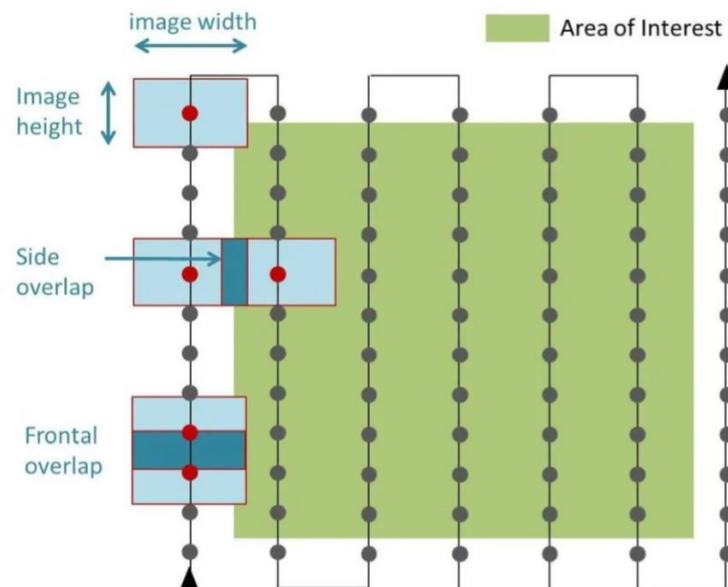


Figura 2-9: Explicación esquemática de solapamiento en vuelo dron [35].

En nuestro caso, para ambos vuelos el objetivo a perseguir era la toma de imágenes sobre una superficie determinada para poder post-procesar un levantamiento fotogramétrico. Para dar contexto sobre la

planificación de dichos vuelos, se van a explicar brevemente los diferentes conceptos relacionados estrechamente con nuestro caso de estudio:

- Altura de vuelo. Para realizar el levantamiento fotogramétrico, conviene que la altura de vuelo sea constante. Por ello, se debe analizar la superficie a fotografiar para detectar la presencia de obstáculos que destaquen en altura por encima del resto, para así poder evitar la colisión del dron durante el vuelo. Una vez se tiene la altura del mayor obstáculo existente, se podrá elegir la altura de vuelo, que en este caso fue de 50 metros.
- Tipo de Rejilla en pasada. Se puede dividir principalmente en pasadas de trayectoria de rejilla de tipo simple o doble (ver Figura 2-8). En el vuelo de 2017, se siguió una trayectoria de doble rejilla.
- Solapamiento o Recubrimiento. Es la superposición parcial de las fotografías tomadas por el dron [referencia solape]. Su misión principal es la de proporcionar una mayor cantidad de datos al software de procesamiento para que pueda establecer una mayor cantidad de puntos comunes entre las imágenes (ver Figura 2-9). El porcentaje de solape suele oscilar en torno al 80% longitudinalmente y al 30% transversalmente.

De los anteriores conceptos relacionados con la planificación del vuelo junto a algunas características inherentes al RPA utilizado aparece relacionado el siguiente parámetro:

- *Ground Sample Distance* (GSD). Es la distancia entre el centro de dos píxeles adyacentes medidos sobre la superficie [36]. Su significado es la medida en la superficie real de un píxel. Para hallar su valor, se sigue la siguiente ecuación:

$$GSD = \frac{t_{\text{píxel}} * H}{f} \quad (2-1)$$

Siendo:

- $t_{\text{píxel}}$ : tamaño del píxel. Se calculará como tamaño del sensor/resolución en píxeles.
- $H$ : altura de vuelo.
- $f$ : distancia focal. En este caso 3.61 mm.

Con los datos de 2017 obtenemos un  $GSD = 0.8 \text{ cm/píxel}$ . Cabe destacar que habría un GSD en ancho y un GSD en alto pero que son, salvo un margen despreciable de error, iguales.

Para concluir este apartado, cabe destacar que se hicieron un total de 1115 fotografías con una resolución de 4000x3000 píxeles y 72 ppp (puntos por pulgada).

## 2.3. Datos Vuelo 2022

El vuelo realizado sobre el Castillo-Fortaleza en 2022 aportará las fotografías con la información necesaria para su posterior procesamiento y obtención del levantamiento fotogramétrico, que dará como resultado su correspondiente ortofotografía y modelo digital de elevaciones. Al existir una diferencia temporal de 5 años entre ambos vuelos, se espera que exista un salto tecnológico en el RPA y la cámara utilizados. A continuación, se especificarán los datos para este nuevo vuelo.

### 2.3.1 Especificaciones del RPA

El modelo de RPA utilizado para el vuelo de 2022 fue el DJI Phantom 4 Pro, un cuadricóptero de 4 rotores de gama media cuyo precio de salida fue de 1800\$. Se trata de una versión mejorada de los anteriores modelos Phantom 4, incorporando unas mejores prestaciones mecánicas y destacando sobre todo la incorporación de un

mayor número de sensores en el perímetro de todo el dron para implementar una mayor y más precisa detección de obstáculos. También presenta sensibles mejoras en la cámara, instalando de serie la FC6310S con 20 megapíxeles, lo que hará que las imágenes tomadas posean una mayor cantidad de información, aunque aumentando por contra su peso.



Figura 2-10: Dron DJI Phantom 4 Pro en fase de vuelo [37].

Las características principales del DJI Phantom 4 Pro se detallan a continuación [38]:

- Dimensiones y peso: Longitud Diagonal 350 mm (sin hélices) con 1388 gramos de peso.
- Autonomía de vuelo: 30 minutos.
- Velocidad ascenso máxima: 6 m/s.
- Velocidad descenso máxima: 4 m/s.
- Velocidad lineal máxima: 20 m/s.
- Altitud máxima: 6000 msnm.
- Detección de obstáculos: Sí, con evitado de colisiones mediante evasión, sobrevuelo o flotación. Rango 0.7 –30 m. En este modelo, a diferencia de su antecesor el DJI Phantom 4, el sistema de Visión, compuesto con sensores de visión estéreo y ultrasónicos, se encuentra en las partes delantera, trasera e inferior del dron, permitiendo una detección de obstáculos de todo el entorno de vuelo de la aeronave. También posee dos sensores infrarrojos 3D a los lados de la aeronave, que sirven para el mismo fin. En la Figura 2-11, se puede observar el rango de detección de obstáculos del RPA.
- Estabilización de vuelo: Sí, 3 ejes (cabeceo, alabeo y guiñada).
- Posicionamiento por satélite: GPS / GLONASS.
- Frecuencia de radiocontrol: 2400 GHz – 2483 GHz y 5725 GHz – 5825 GHz.

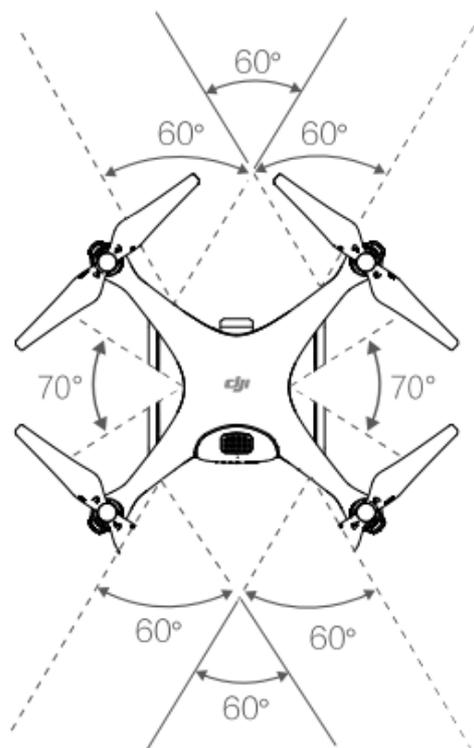


Figura 2-11: Sistema de detección de obstáculos en DJI Phantom 4 Pro [39].

Tras analizar las principales características del DJI Phantom 4 y del DJI Phantom 4 Pro, se puede concluir en que existen pequeñas mejoras en autonomía y en rango de control remoto. El mayor salto en las especificaciones del RPA se puede apreciar en la detección de obstáculos, ya que en el anterior modelo sólo se contaba con detección frontal, mientras que, en el nuevo modelo se ha extendido hacia todas las superficies del dron, aumentando además la distancia de detección desde 15 m hasta 30 m.

### 2.3.2 Especificaciones de la cámara

El RPA DJI Phantom 4 Pro lleva integrada de serie una cámara FC6310S que cuenta también con un sistema *Gimbal* como el mostrado en la Figura 2-7, que permite la rotación de la cámara en un ángulo de 120° con el fin de conseguir imágenes con diferentes ángulos. También cuenta con un sistema de estabilización en 3 ejes que proporciona una plataforma estable para la cámara, permitiendo capturar imágenes y vídeos de forma nítida y estabilizada [39].

Se muestra a continuación el listado de características y especificaciones más relevantes de la cámara [38]:

- Sensor 1” CMOS con 20 Megapíxeles efectivos.
- Objetivo FOV 84° 24 mm (formato equivalente a 35 mm) f/2.8 – f/11 enfoque desde 1 metro - hacia infinito.
- Rango ISO 100-3200 en automático (hasta 6400 en modo manual) para vídeo y 100-3200 en automático (hasta 12800 en modo manual) para fotografía.
- Velocidad obturador mecánico 8 – 1/2000 s.
- Velocidad obturador electrónico 8 – 1/8000 s.
- Modos de fotografía: Disparo único, disparo en ráfaga 3/5/7/10/14, Exposición automática en

horquillado para conseguir un mejor ajuste de exposición.

- Fotografía en JPEG, DNG y JPEG+DNG con opción de añadir Micro SD de hasta 128 GB para almacenamiento.

En el apartado de la cámara, se aprecian notables mejoras en el apartado de la calidad de la imagen, ya que se pasa de un sensor de 12.4 MP a uno de 20 MP, consiguiendo así una mayor cantidad de información en las imágenes obtenidas. Además, al aumentar la calidad de las imágenes, su peso también lo hace, haciendo necesaria una ampliación de la capacidad de la tarjeta Micro SD hasta los 128 GB. Por último, cabe destacar una amplia mejora en el rango de exposición ISO de las fotografías, lo que evitará la obtención de imágenes subexpuestas o sobreexpuestas que puedan ocasionar muestras no válidas durante los vuelos.

### 2.3.3 Características del vuelo

Análogo a lo comentado en el apartado 2.2.3, el vuelo del dron debe de ser planificado para que cumpla con los objetivos fijados en el proyecto. Para este segundo vuelo de 2022, se fijó una altura de 40 metros, dato provisto por el operador del vuelo. Además, nos proporcionó un GSD = 1,1 cm/píxel aproximadamente.

A continuación, comprobaremos que dicho GSD corresponde al que se tiene realmente.

Atendiendo a la ecuación (2-1), necesitamos los siguientes parámetros:

- Tamaño del píxel. Dado que tenemos un sensor 1” CMOS, cuyas medidas son 13.2 mm x 8.8 mm y una resolución de 20 Megapíxeles efectivos, nuestro tamaño de píxel se puede calcular de la siguiente forma:

$$t_{\text{píxel (ancho)}} = \frac{\text{longitud sensor}_{\text{ancho}} [\text{m}]}{\text{tamaño imagen}_{\text{ancho}} [\text{píxels}]} = \frac{0.0132}{5472} = 0.00000241 = 2.41 \frac{\mu\text{m}}{\text{píxel}} \quad (2-2)$$

$$t_{\text{píxel (alto)}} = \frac{\text{longitud sensor}_{\text{alto}} [\text{m}]}{\text{tamaño imagen}_{\text{alto}} [\text{píxels}]} = \frac{0.0088}{3648} = 0.00000241 = 2.41 \frac{\mu\text{m}}{\text{píxel}} \quad (2-3)$$

- Distancia focal. En este caso de 9 mm, este dato se obtiene de las propias fotografías proporcionadas como dato.

Por tanto, el GSD obtenido (tanto en ancho como en alto), tendría un valor de:

$$GSD = \frac{0.00000241 * 40}{0.009} = 0.0107 \frac{\text{m}}{\text{píxel}} = 1.07 \frac{\text{cm}}{\text{píxel}} \quad (2-4)$$

Otra característica importante del vuelo es el tipo de trayectoria seguida por el RPA. En este caso, tras realizar un análisis de las imágenes proporcionadas, se ha deducido que se trató de un vuelo de rejilla doble con la particularidad de que se va a utilizar el sistema *Gimbal* que lleva instalado el dron para poder variar el ángulo de toma de fotografía y así poder tener una mejor muestra del relieve del terreno. A continuación, se muestran algunos ejemplos de ello.



Figura 2-12: Dos imágenes tomadas por el dron secuencialmente.

En la Figura 2-12, se pueden observar dos tomas del dron espaciadas por unos segundos. Las dos imágenes fueron tomadas dentro de la misma línea de vuelo, es decir, dentro de la misma franja de la rejilla. Se aprecia cómo el dron está haciendo uso del *gimbal* instalado para poder realizar tomas en una dirección diferente a su dirección de vuelo. Además, también se puede notar un cierto ángulo de picada que sirve para tener una mejor percepción del relevo de la zona, en este caso de una cumbre.

Se destaca esta particularidad ya que se tienen otras tomas del dron cuyas líneas de vuelo son paralelas a la mostrada en la Figura 2-12, pero cuya dirección de toma de fotografía es perpendicular a ella. A modo de ejemplo, se ilustra en la Figura 2-13.



Figura 2-13: Imagen tomada por el dron en la zona 1 de estudio.

El conjunto de fotografías de este segundo vuelo de 2022 consta de 567 elementos, con un peso total de 4.50 GB. Las dimensiones de las fotografías es de 5472 x 3648 píxeles, con una resolución de 72 ppp.

En la Tabla 2-1, se muestra una comparativa entre las principales características entre los vuelos de 2017 y 2022.

Tabla 2-1: Comparativa de características entre los vuelos 2017 y 2022.

Características	Vuelo 2017	Vuelo 2022
Modelo y precio del dron	DJI Phantom 4, 1000\$	DJI Phantom 4 Pro, 1800\$
Estabilización de vuelo	3 ejes	3 ejes
Posicionamiento satelital	GPS / GLONASS	GPS / GLONASS
Cardán ( <i>Gimbal</i> en inglés)	-90° - 30°	-90° - 30°
Detección de obstáculos	Frontal 0.7-15 m	Perimetral 0.7-30 m
Sensor	1/2.3" 12.4 Mpx	1" 20 MPx
ISO fotografía	100-1600	100-12800
Altura de vuelo	50 m	40 m
Tipo de rejilla de vuelo	Doble	Doble
Distancia de muestra del suelo ( <i>Ground Sample Distance -GSD-</i> )	0.80 cm/píxel	1.07 cm/píxel
Tamaño de fotografías	4000 x 3000 píxeles	5472 x 3648 píxeles
Puntos por pulgada (ppp)	72	72
Distancia focal	3.61 mm	9 mm
Número de fotografías	1115	567

## 2.4. Puntos de control

Los puntos de control son ubicaciones elegidas en el lugar físico de la zona de estudio cuya posición respecto a un determinado sistema de coordenadas es conocido. Su función es georreferenciar el modelo fotogramétrico de estudio con un sistema de referencia espacial. En este caso, el SRC utilizado será el ETRS89 / UTM Zona 30N, donde 30N hace referencia al huso 30 del sistema UTM (siglas en inglés, *Universal Transverse Mercator*) para el hemisferio Norte. Este huso cubre la longitud desde 6° Oeste a 0°, incluyendo así principalmente a la mayor parte de España y Portugal.

Se deben elegir inteligentemente de forma que sean visibles en la mayor parte de las fotografías tomadas por el RPA. Es deseable que se encuentren en un entorno despejado donde puedan ser identificables desde el mayor número posible de ángulos. Además, conviene que se encuentren en zonas amplias y planas, para que, ante una falta de precisión en la elección del conjunto de píxeles, no provoque errores de altura. Por ejemplo, un vértice de un pilar no sería un buen lugar para establecer un PC ya que una falta de precisión al marcar el PC en Metashape, provocaría tener píxeles del mismo PC a diferentes alturas.

La georreferenciación de los puntos de control en el terreno se realiza mediante un receptor GNSS, trabajando en modo diferencial y guardando sus coordenadas. Para la realización de este proyecto, se tienen los puntos de control del Vuelo 2017. Son un total de 71 puntos de control divididos entre las 2 zonas de estudio (47 para la zona 1 y 24 para la zona 2). Cabe destacar que no todos los puntos de control han sido utilizados debido principalmente a que se trataban de zonas que han variado con el paso del tiempo y no son reconocibles.

A continuación, se detallan las posiciones de los PC en ambas zonas y sus coordenadas asociadas en ETRS89 / UTM Zone 30N [27].



Figura 2-14: Puntos de control sobre Zona 1 de estudio.

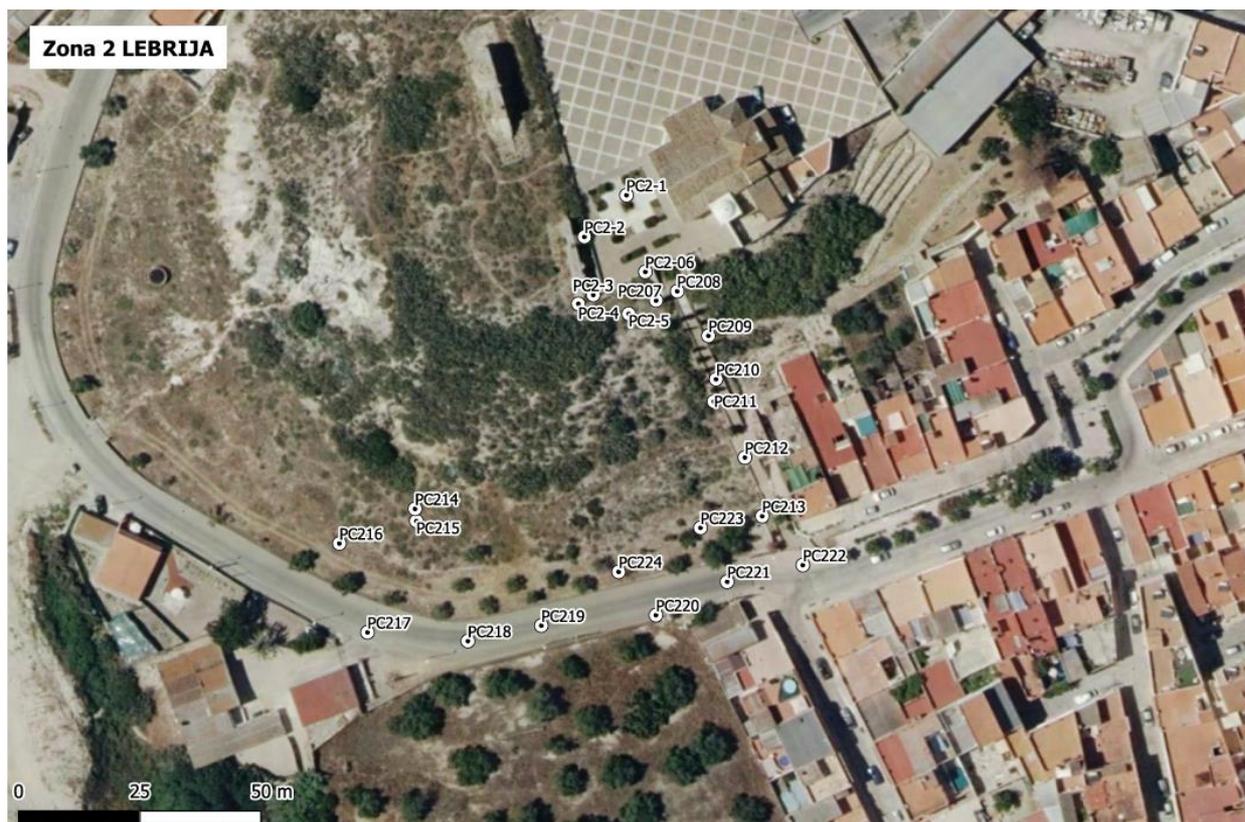


Figura 2-15: Puntos de control sobre Zona 2 de estudio.

Tabla 2-2: Coordenadas Puntos de Control en Zona 1.

ID	X (m)	Y (m)	H (m)
PC47	225278.7814	4090348.6377	63.400
PC46	225420.4790	4090331.9173	62.017
PC45	225415.4617	4090335.2265	62.510
PC44	225377.2681	4090326.3769	62.311
PC43	225369.5245	4090329.7673	62.621
PC42	225361.6735	4090335.6979	62.754
PC41	225357.3960	4090350.2289	62.623
PC40	225346.1139	4090341.4980	62.703
PC39	225336.4402	4090340.1077	63.119
PC38	225314.7141	4090341.1476	63.321
PC37	225306.2888	4090353.5691	63.285
PC36	225298.2349	4090348.7407	62.604
PC35	225293.5414	4090349.5123	62.837
PC34	225273.2160	4090350.5185	63.403
PC33	225263.4768	4090340.3761	64.660
PC32	225254.6265	4090338.0948	67.258
PC31	225248.8688	4090338.4749	67.523
PC30	225248.6438	4090331.3480	66.701
PC29	225253.5796	4090334.2115	66.658
PC28	225277.3599	4090323.5232	64.739
PC27	225300.5579	4090336.0672	61.517
PC26	225302.9429	4090335.4228	61.238

PC25	225307.2802	4090338.2995	60.936
PC24	225339.3214	4090324.9593	57.203
PC23	225419.0446	4090428.6044	37.344
PC22	225417.7451	4090432.8786	36.008
PC21	225415.7539	4090432.5112	35.251
PC20	225410.8520	4090440.5771	36.405
PC19	225407.9249	4090449.9667	35.451
PC18	225406.5882	4090471.2019	29.846
PC17	225395.3958	4090461.3496	31.790
PC16	225392.3070	4090455.3641	32.243
PC15	225287.4570	4090467.7192	31.885
PC14	225262.4232	4090470.2357	32.488
PC13	225257.1086	4090472.2491	32.687
PC12	225286.5280	4090446.1656	39.166
PC11	225306.2631	4090447.1129	39.427
PC10	225328.7349	4090428.1061	40.559
PC9	225329.4169	4090421.2632	43.637
PC8	225241.9278	4090374.5002	43.730
PC7	225250.5168	4090374.4996	43.111
PC6	225254.5844	4090388.1226	41.534
PC5	225257.8833	4090399.6388	40.906
PC4	225251.9631	4090407.4392	39.935
PC3	225258.4785	4090415.3775	39.953
PC2	225269.2060	4090444.3878	38.257
PC1	225251.3368	4090437.9841	36.729

Tabla 2-3: Coordenadas Puntos de Control Zona 2.

ID	X (m)	Y (m)	H (m)
PC224	225228.972	4090200.940	41.927
PC223	225245.857	4090210.090	42.602
PC222	225266.969	4090202.341	39.268
PC221	225251.355	4090198.876	39.396
PC220	225236.659	4090191.937	40.152
PC219	225213.030	4090189.765	40.969
PC218	225197.870	4090186.547	40.692
PC217	225177.170	4090188.365	39.253
PC216	225171.371	4090206.848	39.540
PC215	225187.250	4090211.507	42.549
PC214	225186.976	4090214.042	42.722
PC213	225258.590	4090212.516	43.332
PC212	225255.012	4090224.719	48.217
PC211	225248.631	4090236.373	51.851
PC210	225249.072	4090240.995	54.252
PC209	225247.493	4090250.037	57.682
PC208	225241.051	4090259.289	63.336
PC207	225236.691	4090257.374	65.085
PC2-6	225234.473	4090263.321	68.214

PC2-5	225231.044	4090254.602	63.454
PC2-4	225220.650	4090256.673	66.830
PC2-3	225223.734	4090258.520	66.924
PC2-2	225221.910	4090270.598	67.836
PC2-1	225230.591	4090279.257	67.047

## 2.5. Especificaciones Hardware

Para el desarrollo del proyecto se requerirá un procesamiento vía software (Metashape, QGIS, etc) de las imágenes obtenidas y de los datos derivados de ellas. Para el procesamiento en Metashape, se requiere de una gran capacidad gráfica, es conveniente que el ordenador posea una tarjeta gráfica dedicada. En este caso, el ordenador principal de trabajo, aun poseyéndola, no fue capaz de procesar al completo el modelo. Por ello, se hizo dicho procesamiento en un ordenador secundario en la ETSIA. A continuación, se detallan las características de ambos ordenadores.

- Ordenador principal.
  - Sistema operativo: Windows 10 Home.
  - Procesador: Intel(R) Core(TM) i7-7700HQ CPU @ 2.80GHz 2.81 GHz.
  - RAM: 8 GB.
  - Tarjeta gráfica: NVIDIA GeForce GTX 1050 8 GB.
- Ordenador secundario.
  - Sistema operativo: Windows 10.
  - Procesador: Intel(R) Core(TM) i9-13900K 3.00 GHz.
  - RAM: 64 GB.
  - Tarjeta gráfica: NVIDIA GeForce RTX 4090 24 GB.



## 3 METODOLOGÍA

---

El desarrollo del proyecto se divide en dos partes bien diferenciadas, cada una con su propia metodología y objetivos específicos. En este apartado se mostrarán los métodos y procedimientos seguidos para la resolución de ambas partes.

En primer lugar, se tienen como datos de entrada las fotografías aéreas tomadas por el RPA sobre las zonas 1 y 2 de Lebríja. Se aplicará la disciplina de la fotogrametría, que permite obtener modelos tridimensionales a partir de conjuntos de imágenes bidimensionales. Por tanto, a partir de dichas fotografías, se generará un modelo en tres dimensiones, que, tras un posterior procesado, dará lugar a la obtención de la ortofotografía, la cual es una representación fotográfica de un terreno en la que todos los elementos presentan la misma escala y no existen deformaciones, y al modelo digital de elevaciones, que reflejará la topografía específica de las zonas de estudio. El levantamiento fotogramétrico será resuelto mediante la utilización del software comercial Agisoft Metashape®. El proceso será detallado y se mostrarán las principales fortalezas y debilidades del programa.

En segundo lugar, se tomarán como datos de entrada las ortofotografías y los modelos digitales de elevaciones obtenidos como producto de ambos vuelos. El objetivo de esta parte es analizar y conseguir un modelo de clasificación automática para detectar las variaciones en el terreno, con un enfoque más orientado a los cambios de la vegetación. Se hará uso de QGIS, un software libre ampliamente conocido en el ámbito de los Sistemas de Información Geográfica (SIG). Además, se utilizarán tanto su consola de programación en Python para la automatización de procesos y el complemento Semi-Automatic Classification Plugin, donde se aplicarán técnicas de Machine Learning para categorizar las variaciones en el terreno.

### 3.1 Especificaciones de Software

Para comenzar a explicar la metodología utilizada para el desarrollo del TFM, es necesario explicar las características generales del software del que se ha hecho uso.

Para la realización del levantamiento fotogramétrico se ha utilizado Agisoft Metashape®. Se trata de un software comercial especializado en el tratamiento de imágenes digitales para la generación de modelos tridimensionales, ortofotografías, modelos altimétricos, mediciones de volumen, etc. Posee una buena compatibilidad de salida de datos posterior hacia software SIG. Destaca por la facilidad de generación de modelos precisos con un relativo bajo costo computacional, haciendo posible su utilización incluso a personas que se encuentren en niveles iniciales de conocimiento sobre fotogrametría. Es ampliamente utilizado en sectores de Ingeniería, Topografía, Agricultura, Minería, Arqueología, Cine... y también en universidades y centros de investigación. La versión utilizada para este TFM es la Agisoft Metashape® Version 1.8.5 (64 bit).

En cuanto al posterior procesado de datos, se ha utilizado QGIS® como software SIG. Se trata de un programa de uso libre y de código abierto. Su principal función es la del análisis y visualización de información geoespacial, la creación de mapa, el tratamiento de capas y bandas en imágenes multispectrales, etc. Debido a su facilidad de uso, su versatilidad en la instalación de complementos y el desarrollo de nuevas funcionalidades constante que recibe debido a que es de código abierto, junto a que es gratuito, hacen que sea una de las opciones más elegidas a nivel mundial en su segmento. La versión utilizada para este TFM es la QGIS® 3.34.11.

Dentro de QGIS® se ha hecho uso de la consola de Python para QGIS (PyQGIS). Python es el lenguaje de

programación integrado en el programa, por lo que se permite la creación de códigos para la automatización de tareas, el procesamiento y análisis de datos, la creación de complementos para QGIS®, etc. En este TFM, para la codificación de pequeños *scripts* (códigos en español), se ha requerido soporte de la Inteligencia Artificial desarrollada por OpenAI®, ChatGPT®.

Por último, también dentro de la interfaz de QGIS®, se ha utilizado el complemento Semi-Automatic Classification Plugin (SCP), Complemento de Clasificación Semiautomática en español. Se trata de un complemento orientado al análisis y teledetección de imágenes satelitales o fotografías aéreas y que hace uso de algoritmos de ML para ello.

## 3.2 Levantamiento fotogramétrico en Agisoft Metashape®

Para llevar a cabo la resolución del levantamiento fotogramétrico se va a utilizar el software comercial Agisoft Metashape®. Se trata de un programa avanzado especializado en la obtención de modelos espaciales en tres dimensiones mediante el procesamiento de imágenes bidimensionales. La explicación técnica del proceso interno que sigue el programa en proceso efectuado ha sido obtenida de los manuales de usuario de las referencias [40].

Tal y como se muestra en la Figura 3-1, el diagrama de flujo a seguir se puede dividir en 5 fases diferenciadas:

1. **Carga y orientación de fotografías:** En este punto dotamos al programa de la información necesaria mediante el conjunto de fotografías aéreas tomadas por el dron. Una vez tenemos las imágenes cargadas, pasamos a su orientación, donde el software realizará un cruce de puntos en común entre todas las fotografías, dando lugar a la obtención de las posiciones de las cámaras y a la creación de una nube de puntos dispersos.
2. **Generación de nube de puntos densa:** Se trata de la etapa donde más potencia de procesado es necesaria, ya que utiliza las posiciones de las cámaras y la nube de puntos dispersos para proyectar millones de puntos en las tres dimensiones. Estos puntos poseen las propiedades de posición, color y geometría del objeto.
3. **Generación de mallado:** Utiliza la nube de puntos densas en tres dimensiones para, utilizando polígonos, conectar los puntos contenidos en la nube, generando así una superficie continua.
4. **Generación de textura:** Se le da textura a la malla para fidelizar el modelo a la realidad. Se utilizan las propias imágenes aéreas para obtener los atributos reales característicos de cada punto.
5. **Salida de datos:** Generación de ortofotografía, modelo digital de elevaciones e informe de Metashape®, una vez se tiene el modelo texturizado.

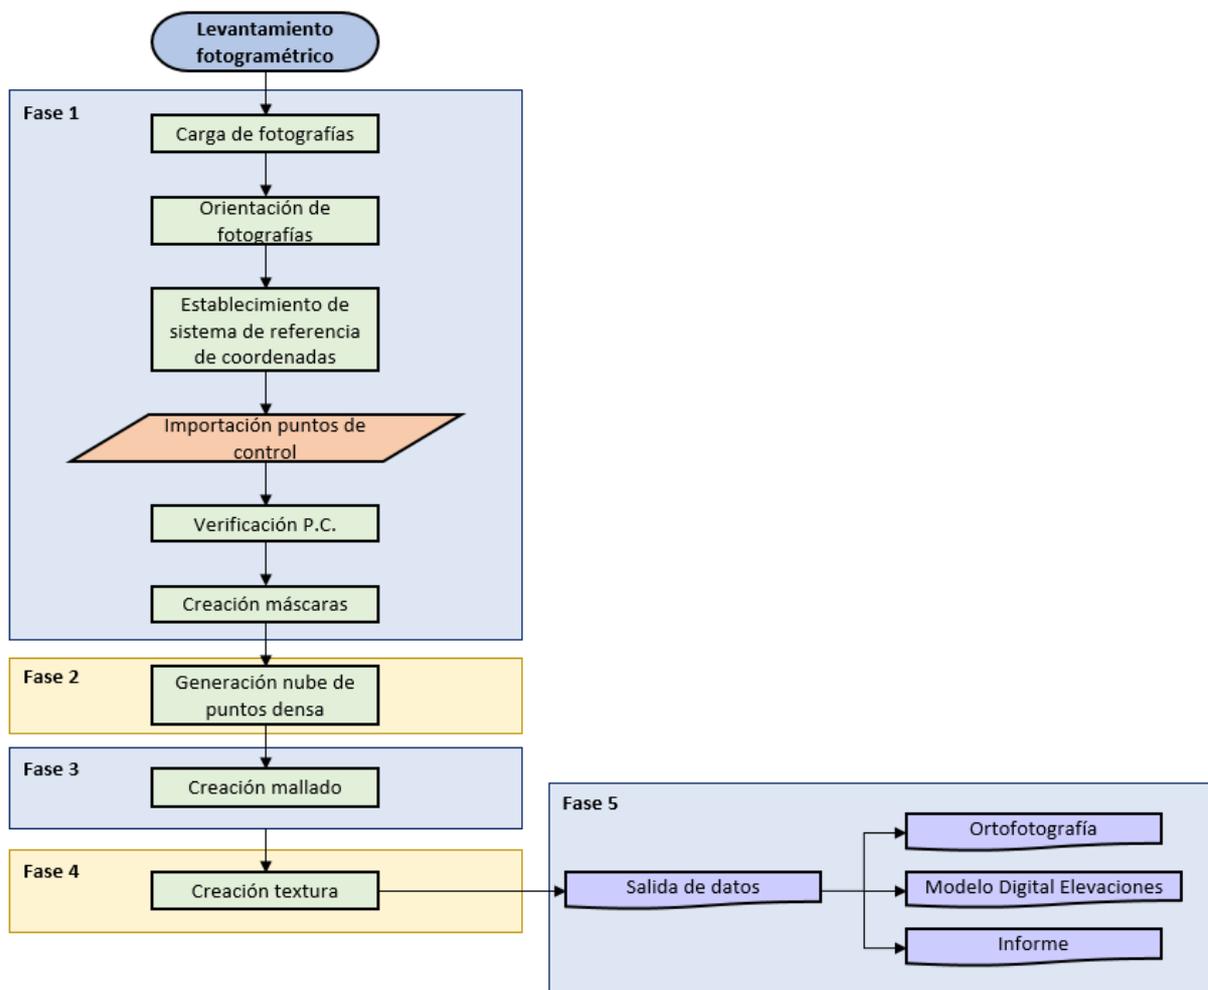


Figura 3-1: Diagrama de flujo del proceso seguido en Metashape®.

Un punto positivo que cabe destacar sobre Metashape® es lo intuitivo que es su flujo de trabajo, ya que ordena de principio a fin las diferentes fases y posibilidades de procesamiento, sirviendo de guía. Además, dependiendo del punto en el que se encuentre el proyecto, algunas opciones se tienen bloqueadas, y se irán desbloqueando según el avance (Figura 3-2).

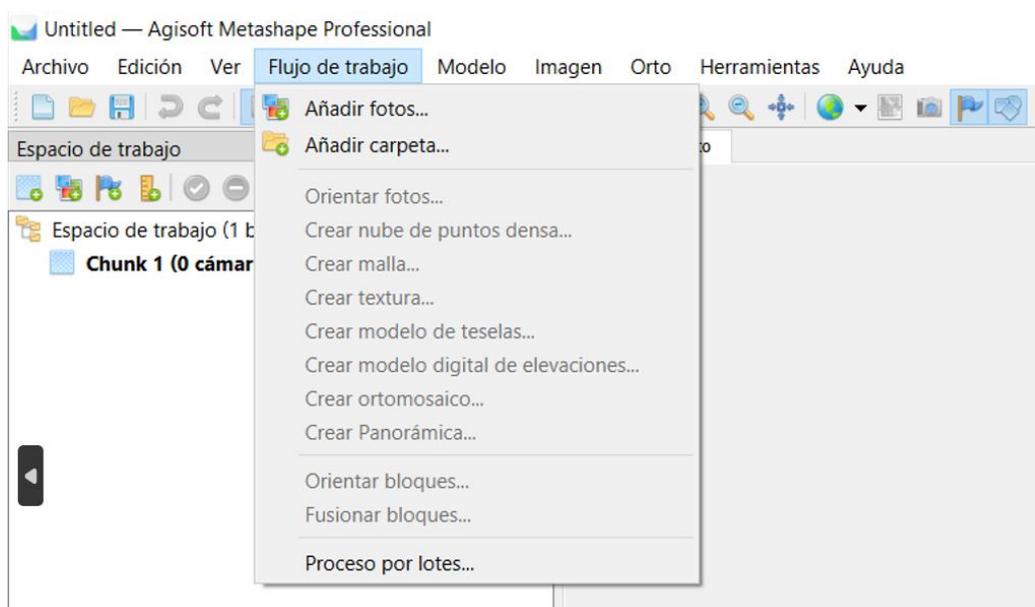


Figura 3-2: Interfaz de flujo de trabajo en Metashape®.

A modo de introducción y de dar contexto al uso del programa, se va a presentar la interfaz inicial de Metashape® (ver Figura 3-3). En la parte superior se tiene la “Barra de menús”, donde se destaca la pestaña de flujo de trabajo, y la “Barra de herramientas rápidas”, donde se tiene acceso directo a funciones con mucho uso durante el flujo de trabajo, como la elaboración de polígonos para la creación de máscaras. La parte izquierda se encuentra ocupada por las pestañas “Espacio de trabajo” y “Referencia”. En la primera, se muestran los elementos del proyecto como las imágenes importadas, la nube de puntos densa, la ortofotografía, etc., mientras que en la segunda se puede encontrar la información relativa al referenciación respecto a un sistema de referencia. Se tiene el despliegue completo de las cámaras y los puntos de control, indicando parámetros de su georreferenciación, su orientación, su precisión, etc. En el área central de trabajo, se presenta el modelo en 3 dimensiones que se vaya generando. Debajo de esta área central está la consola del programa, que muestra un registro de los procesos que se van procesando. Por último, a la derecha se observa el apartado de las imágenes importadas, que será de utilidad a la hora de posicionar en ellas los puntos de control.

Como se comentó en la sección 2.5, conviene que el ordenador de trabajo tenga una tarjeta gráfica dedicada. Para especificarle a Metashape que trabaje con dicha tarjeta, se seleccionará la opción en la *Barra de menús*>*Herramientas*>*Preferencias*>*GPU*.

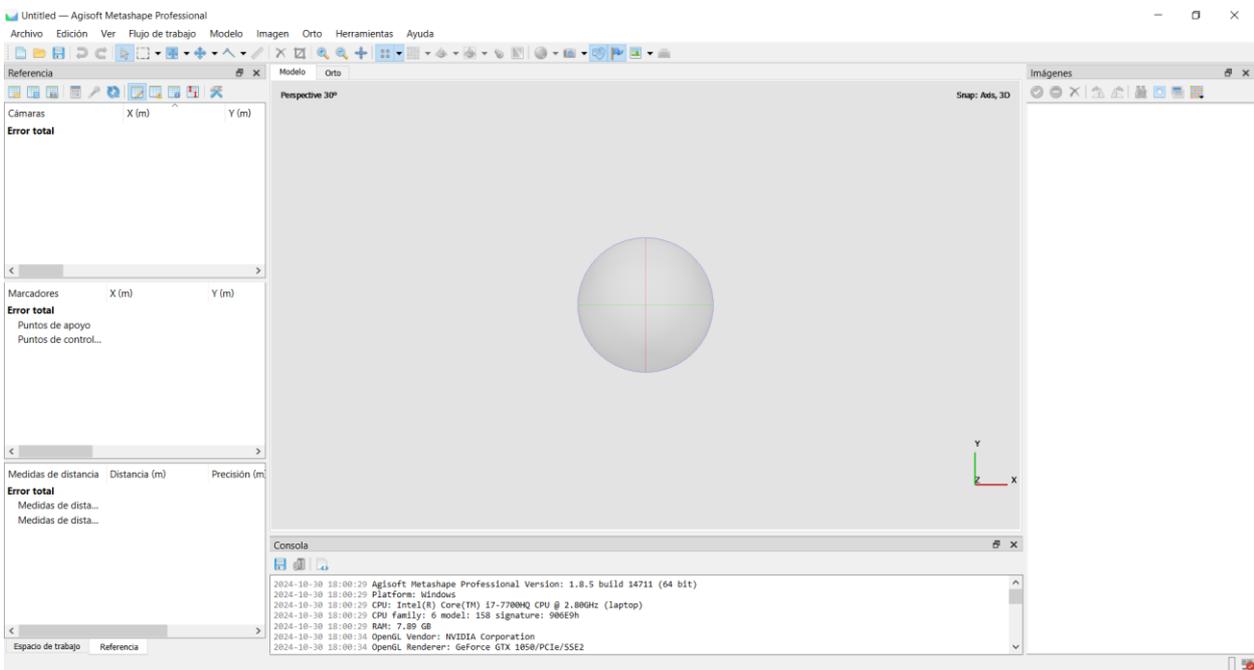


Figura 3-3: Interfaz para nuevo proyecto en Metashape®.

### 3.2.1 Carga y orientación de fotografías

Debido al gran volumen de fotografías que se va a manejar, antes de cargar las fotografías conviene realizar algunas comprobaciones previas, ya que el descarte de fotografías no válidas ayudaría a aliviar la carga de procesamiento del programa. En este caso, se optó por una revisión manual, se comprobó que todas las fotografías se habían tomado con un buen enfoque y exposición. La comprobación de la exposición toma más importancia durante vuelos largos, ya que la posición del sol podría variar, dando lugar a obtener fotos subexpuestas o sobreexpuestas. Este chequeo previo también puede ser realizado automáticamente con softwares del tipo Adobe Lightroom®.

Otra comprobación que conviene realizar es la del solapamiento entre las fotografías. Bien es cierto que es algo difícil de cuantificar a gran escala, teniendo un número tan grande de muestras, más de 500, se puede comprobar que las tomas están espaciadas cada pocos segundos, dando lugar a un solape longitudinal elevado. En cuanto al solape transversal, también se puede comprobar que la rejilla que traza el dron dista en poca distancia entre sus líneas paralelas. En la Figura 3-4 se muestran dos ejemplos donde se puede comprobar

un solape adecuado, tanto longitudinal como transversal.

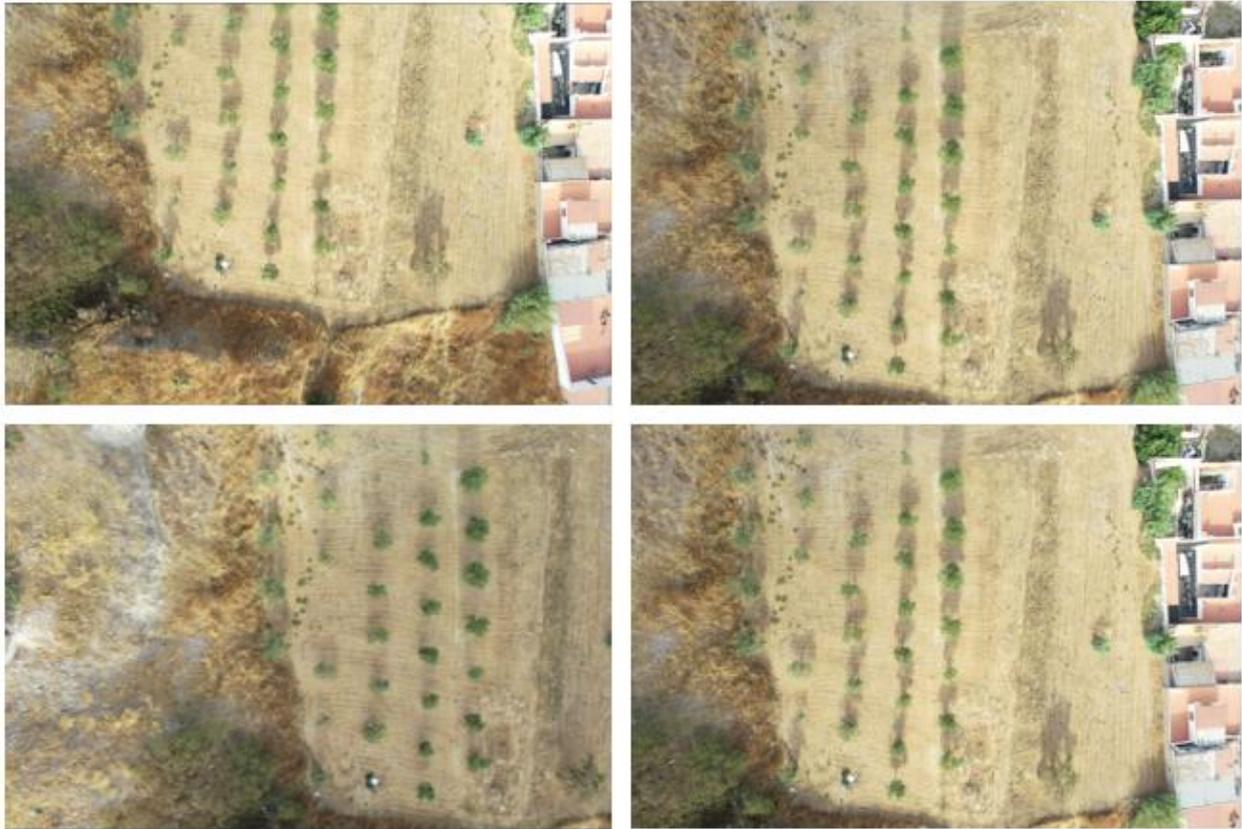


Figura 3-4: Muestra de fotografías donde se aprecia un solape longitudinal (arriba) y transversal (abajo) apropiado.

Una vez se ha realizado el triaje de las fotografías, se procede a cargarlas en el proyecto de Metashape, para ello, atendiendo a la Figura 3-2, se ven las opciones de cargar las fotos seleccionándolas en bloque utilizando *Añadir fotos...* o directamente cargando la carpeta con *Añadir carpeta...* Al completarse la carga de fotografías, éstas aparecerán en el apartado contenido a la derecha de la interfaz, *Imágenes*. En este caso de estudio, el formato de las imágenes es “.JPG”.

Continuando con el flujo de trabajo, se procederá a la orientación de las fotografías. La posición de la cámara en el momento de la captura viene definida por dos tipos de parámetros, interiores, que contienen datos como las coordenadas de la cámara, la distancia focal, etc., y los exteriores, que definen la posición (componentes en 3 ejes de traslación) y la orientación (componentes en 3 ejes Eulerianos de ángulos de rotación). El resultado de la orientación de las fotografías será por un lado conocer la posición y orientación de la cámara respecto al terreno y, además, la creación de una nube de puntos dispersos que contiene la posición triangulada de puntos en común enlazados entre fotografías.

Atendiendo a la Figura 3-5, se hace clic en *Orientar fotos*. Es importante recalcar que la precisión de la orientación deberá ser “Alta”, ya que permite a Metashape trabajar con las fotos en su tamaño original. Se seleccionan las opciones de “Pre-selección genérica”, para agilizar el proceso de elección de fotografías que poseen puntos en común y “Anular orientación de cámaras actual”, para que comience el proceso de búsqueda de puntos en común en fotografías desde cero. El resto de los parámetros se dejan por defecto.

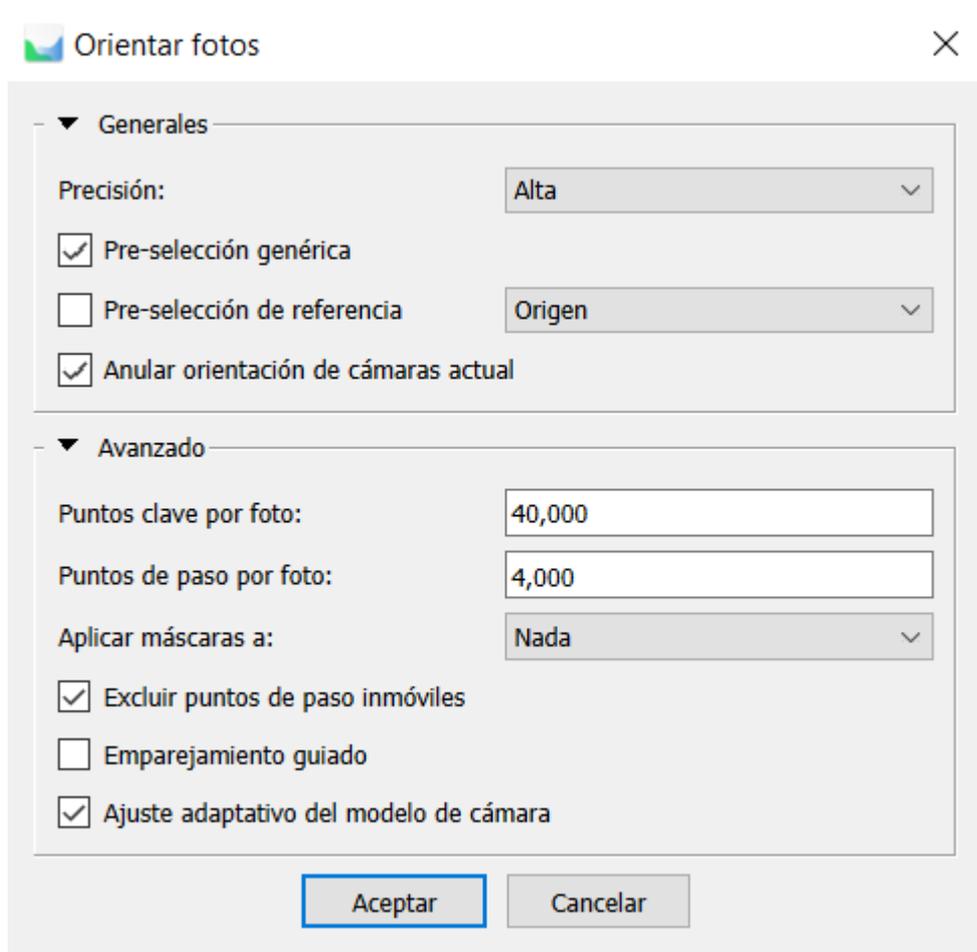


Figura 3-5: Menú desplegado al proceder a la orientación de fotografías en Metashape®.

Las fotografías contendrán la información de coordenadas propias del dron que, por norma general, carecen de precisión y de compatibilidad si se quiere exportar el modelo posteriormente. Por ello, se procederá a borrar las coordenadas originales para, posteriormente, en la pestaña *Referencia* y haciendo uso de los *Ajustes del sistema de referencia*, elegir el sistema de coordenadas ETRS89 / UTM zona 30N (EPSG:25830), tal y como se muestra en la Figura 3-6.



Figura 3-6: Elección del sistema de referencia deseado en Metashape®.

El siguiente paso a realizar es la identificación de puntos de control sobre las fotografías tomadas por el dron. Tal y como se destacó en la sección 2.4, los puntos de control deben cumplir una serie de requisitos para poder ser considerados válidos. Estos requisitos se basan principalmente en la posibilidad de ser identificados en las propias fotografías, que se encuentren en superficies planas que no tengan variaciones grandes de altura en su entorno cercano, que tengan proyección en al menos unas 10 fotografías y, particularmente en este proyecto, que estén establecidos en lugares invariantes con el paso del tiempo.

Para importar los puntos de control, pulsaremos sobre “*Importar referencia*” dentro de la pestaña *Referencia* (ver Figura 3-3). Los puntos de control (PC) se tienen en un archivo \*.txt y el programa da la opción de elegir el carácter elegido como espaciador, en nuestro caso, la coma.

```
lebrija_corregidas_h.txt: Bloc de notas
Archivo Edición Formato Ver Ayuda
PC47,225278.7814,4090348.6377,63.4008,
PC46,225420.4790,4090331.9173,62.0172,
PC45,225415.4617,4090335.2265,62.5102,
PC44,225377.2681,4090326.3769,62.3116,
```

Figura 3-7: Formato de introducción de PC.

Cada identificación de un PC en una fotografía es denominada proyección. Se establece un umbral mínimo de 10 proyecciones por PC para asegurar unos márgenes de error bajos. El código de colores para los PC de Metashape se puede dividir en:

- Verde: Coincidencia fiable y utilizada para el cálculo.
- Azul: Coincidencia baja, sólo utilizada si no existen proyecciones con alta fiabilidad.
- Gris: No utilizada para el cálculo.

Una vez se tiene el mayor número posible de proyecciones de los puntos de control verificada, se pretende reducir el error total que puedan presentar. Metashape posee una función llamada *Optimizar cámara*, dentro de la pestaña *Referencia*, que ajusta los parámetros internos y externos de orientación de las cámaras para reducir el error general del proyecto. El programa se ayudará también de los propios puntos de control para mejorar la precisión.

Para concluir esta fase, sólo queda la aplicación de máscaras para la omisión de elementos móviles en el levantamiento fotogramétrico. Se consideran elementos móviles aquellos que varían su posición entre las tomas fotográficas. Desde la *Barra de herramientas rápidas* se seleccionan las *Tijeras inteligentes* y se crean polígonos cerrados cubriendo los elementos móviles. Posteriormente, se pulsa clic derecho y se añade la selección.



Figura 3-8: Ejemplo de elemento móvil (persona) cubierto con máscara en Metashape®.

### 3.2.2 Generación de nube de puntos densa

El siguiente paso a seguir en el *Flujo de trabajo* será la creación de la nube de puntos densa. Se construye mediante el uso de la anterior nube de puntos dispersa y la orientación de las cámaras. Este proceso proyecta los puntos existentes en las tres dimensiones creando así una estructura más concentrada de puntos que, además, poseen atributos de color RGB, generando así una representación tridimensional fiel a la realidad.

Entre los parámetros a elegir a la hora de crear la nube de puntos densa, se seleccionó *Calidad* “Media” debido a la cantidad de fotografías a procesar. Aún se podría elevar este parámetro a Extra Alta, aumentando así la resolución a la que se procesan las fotografías hasta su tamaño original. Del resto de parámetros, sólo cabe destacar el *Filtrado de profundidad*, donde, mediante algoritmos internos de filtrado, Metashape puede eliminar del procesado datos atípicos o aislados dentro de las imágenes. Eligiendo “Moderado” se espera que se eliminen la mayoría de los valores atípicos.

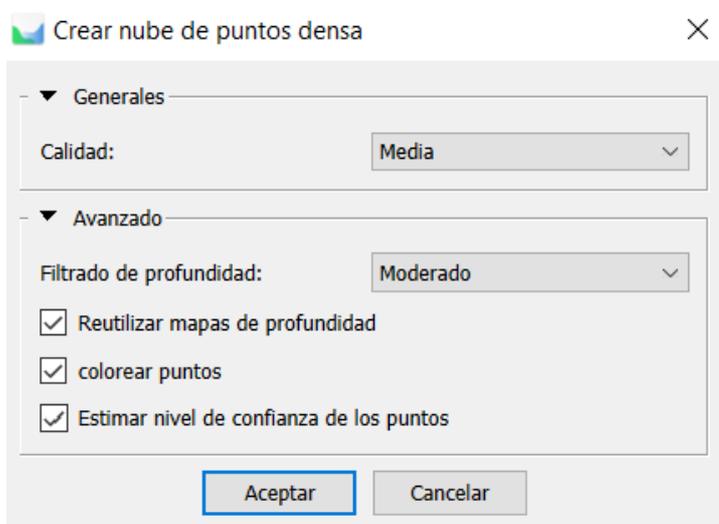


Figura 3-9: Interfaz de creación de nube de puntos densa en Metashape®.

Los requerimientos de procesamiento necesarios no hicieron posible la obtención de la nube de puntos densa en el ordenador principal, ya que, tras 12 horas de procesamiento, Metashape se cerró inesperadamente sin terminar el proceso. Por tanto, se hizo uso del ordenador secundario de la ETSIA para realizar el procesado, tardando éste 50 minutos.

### 3.2.3 Generación de mallado

Una vez se tiene la nube de puntos densa, y continuando con el *Flujo de trabajo*, se procede con la generación del mallado. El mallado transforma la nube de puntos densa en una estructura unida poligonalmente mediante puntos de enlace, es decir, utiliza la nube de puntos densa para la creación de un modelo tridimensional basado en la unión de polígonos.

Abriendo el desplegable del *Flujo de trabajo* (ver Figura 3-2), se pulsa en *Crear malla...* y aparece un desplegable como se puede ver en la Figura 3-10. Se debe seleccionar el *Origen de los datos: Nube de puntos densa*, el *Tipo de superficie: Arbitrario (3D)*, que es el predeterminado para modelar cualquier tipo de objeto. En *Número de caras*, se elegirá *Media* o *Alta*, según la capacidad de procesado que se tenga, en nuestro caso se eligió *Alta*. La *Interpolación* se encontrará habilitada, por lo que si existe algún hueco dentro de la estructura será cubierto utilizando características de puntos vecinos al hueco.

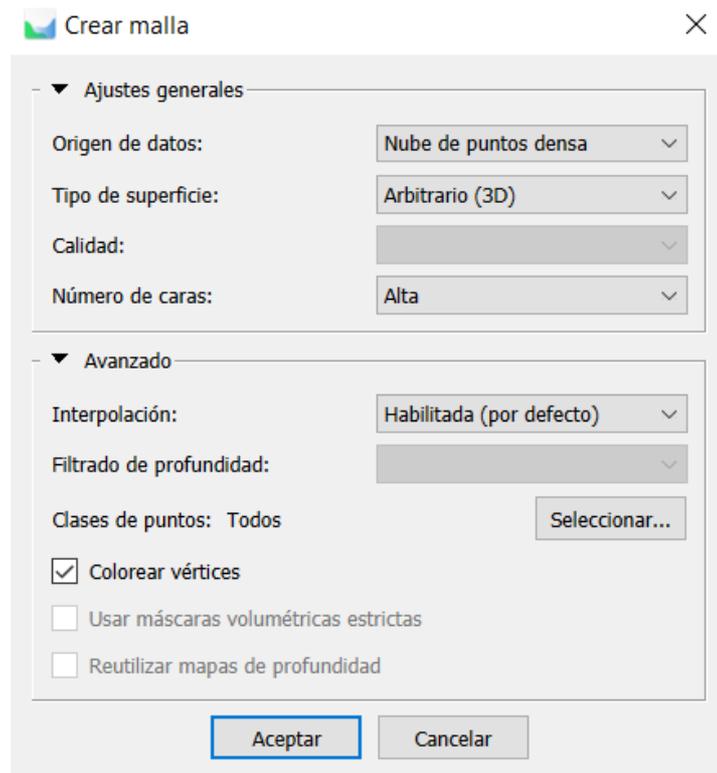


Figura 3-10: Interfaz de creación de malla en Metashape ®.

### 3.2.4 Generación de textura

Con la malla del modelo generada, se pasa a la generación de la textura. La función de texturizar el modelo tridimensional es la creación de una imagen continua sobre la malla. Esta imagen es una representación fiel a la realidad del terreno, ya que se representan los colores RGB obtenidos de las fotografías aéreas sobre la textura creada, mejorando la apariencia visual y el nivel de detalle del modelo.

Continuando con el *Flujo de trabajo* > *Crear textura...* Como parámetros elegiremos *Tipo de textura: Mapa de RGB*, ya que se busca una representación con colores fieles a la realidad, con *Origen de datos: Imágenes*, *Modo de mapeado: Genérico* y *Tamaño/número de texturas: 8192*, consiguiendo así un tamaño de la textura en píxeles que proporciona una buena resolución. Al igual que con el mallado, se habilita el cierre de agujeros.

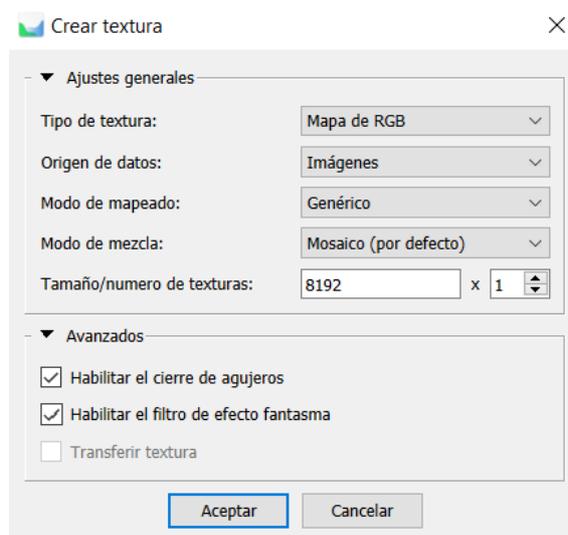


Figura 3-11: Interfaz de creación de textura en Metashape ®.

### 3.2.5 Salida de datos. Generación de modelo digital de elevaciones, ortofotografía, e informe

Una vez se tiene el modelo tridimensional completamente procesado, se procede a obtener los diferentes productos que son del interés del proyecto.

En primer lugar, se obtiene el Modelo Digital de Elevaciones, que es una representación en dos dimensiones en la que cada punto marca el valor de altura en el terreno. Para calcularlo, se procede con *Flujo de trabajo*>*Crear modelo digital de elevaciones...* El único parámetro a definir en el cuadro de texto que aparece es el tipo de *Proyección* deseado, en nuestro caso se utilizará el georreferenciado a ETRS89 / UTM zona 30N (EPSG: 25830).

Para obtener la ortofotografía, se seguirá el *Flujo de Trabajo*>*Crear ortomosaico...* Se obtendrá la ortofotografía basada en el MDE. En *Tamaño de píxel*, se dejará el valor que aparezca por defecto ya que será el que obtenga el programa de la resolución del muestreo del terreno.

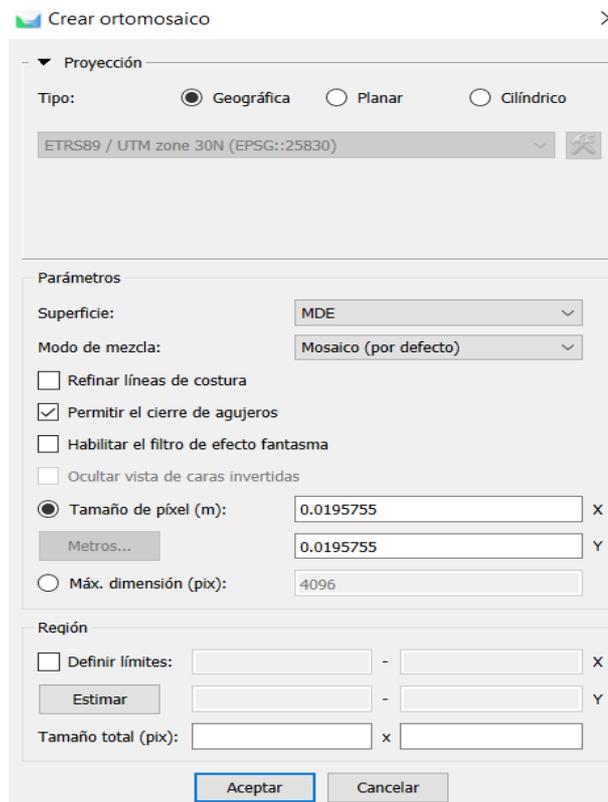


Figura 3-12: Interfaz de creación de ortofotografía en Metashape®.

Por último, Metashape® da la posibilidad de generar un informe de forma automatizada que contiene un detallado resumen del proyecto. Se presentan datos tales como el número y resolución de las fotos procesadas, la posición de las cámaras, las coordenadas y el error de los puntos de control y detalles técnicos de los productos obtenidos (Mallado, Textura, MDE, ortofotografía, etc.).

Para su obtención, debemos ir a la *Barra de menús*>*Archivo*>*Exportar*>*Generar informe...*

### 3.3 Detección de cambios superficiales en el terreno mediante ML

Para la detección de los cambios superficiales que se han producido en el terreno entre los vuelos de 2017 y 2022, se va a hacer uso del software QGIS®, que es un Sistema de Información Geográfica, específicamente de su consola de programación en Python, PyQGIS y de un complemento de teledetección mediante ML llamado Semi-Automatic Classification Plugin (SPC), desarrollado por Luca Congedo [43].

Tal y como se muestra en la Figura 3-13, el diagrama de flujo a seguir se puede dividir en 4 fases diferenciadas:

1. Carga de datos y establecimiento de formato adecuado. Las dos ortofotografías y MDE serán cargados en formato \*.tif en QGIS®. Debido a que para 2017 se tienen tanto la ortofotografía y MDE divididos por cada zona de estudios, 1 y 2, los datos de 2022 deben ser recortados y adaptados para tener el mismo corte imágenes.
2. Instalación de librerías y complementos. Para la realización de los procesos de detección.
3. Creación de ráster de diferencias. Se creará una imagen en formato \*.tif que contenga, por bandas, la diferencia entre los datos de 2017 y 2022.
4. Detección de cambios y salida de datos. Se utilizarán algoritmos de ML y códigos en lenguaje de programación Python para abordar la detección de cambios.

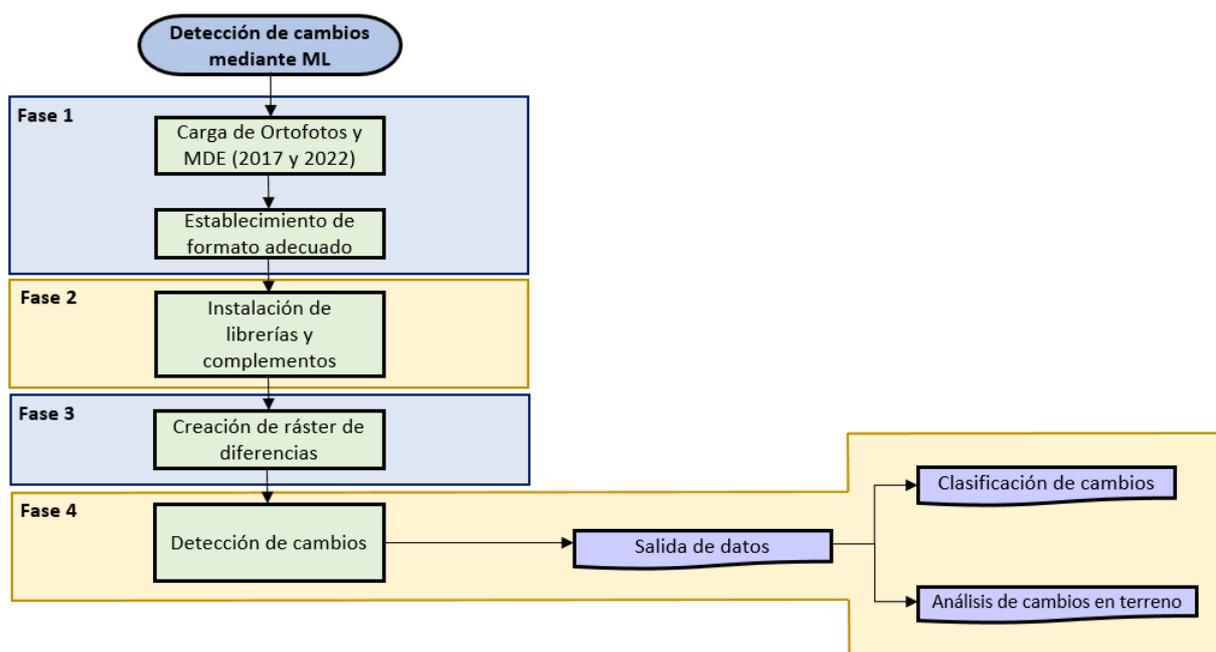


Figura 3-13: Diagrama de flujo seguido en proceso de detección de cambios.

### 3.3.1 Carga de datos y establecimiento de formato adecuado

En primer lugar, se debe definir el concepto de “ráster”. Se trata de una representación de datos espaciales en un conjunto de píxeles. Cada píxel contiene un valor que representa información específica del espacio que representa. El formato ráster se utiliza en programas SIG, como QGIS®, y destaca por su composición en diferentes bandas que pueden albergar diferentes tipologías de datos, como por ejemplo valores de color RGB o valores de altitud, es decir, un mismo píxel puede albergar datos RGB y altimétricos. En este caso, también se ha elegido QGIS® debido a la facilidad que proporciona a la hora de realizar representaciones visuales y del manejo de bandas.

Para proceder a la carga de datos ráster, se clicará en *Capa* > *Administrador de fuentes de datos*, se seleccionarán los archivos necesarios y se pulsará sobre *Añadir*. Es importante tener georreferenciados correctamente al sistema de referencia de coordenadas deseado. Para ello, una vez se carguen los ráster en la sección de *Capas* (ver Figura 3-14), se clicará dos veces en la capa a georreferenciar, se entrará a la sección *Fuente* y se elegirá el SRC EPSG:25830.

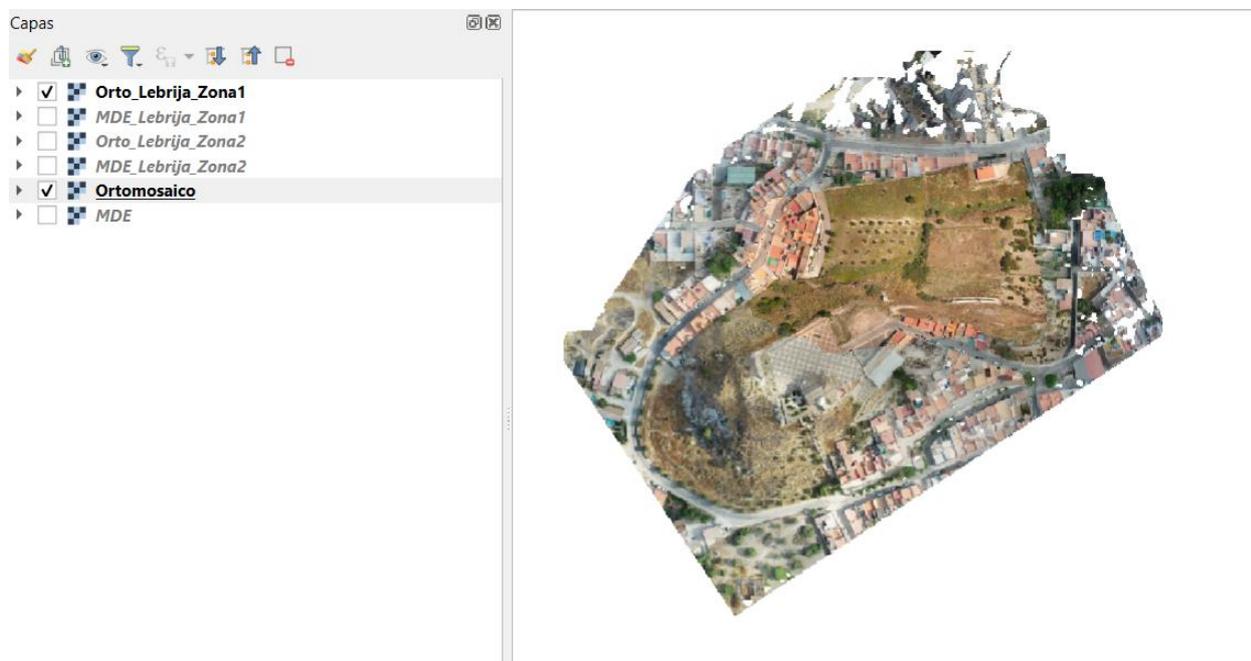


Figura 3-14: Captura de QGIS® donde se aprecian las capas cargadas y la ortofoto de la Zona 1 de 2017 superpuesta a la ortofoto del modelo completo de 2022.

Debido a que, en el proyecto de 2017, la salida de ortofotografías y MDE se realizó individual para las Zonas 1 y 2, ahora se deberá recortar la ortofotografía de 2022 por esas dos mismas secciones para poder trabajar con exactamente los mismos cortes del terreno. Para ello, se va a crear un polígono en forma de rectángulo que recoja la máxima cantidad posible de superficie de la ortofotografía de 2017 y, posteriormente, se van a cortar las dos ortofotografías a través de ese rectángulo. Se clicó en *Capa* > *Crear capa* > *Nueva capa de archivo shape...* En la Figura 3-15, se puede ver la interfaz que aparece y los parámetros a introducir. Se habrá creado una capa dentro del espacio de *Capas*. Ahora se debe crear la forma del polígono, para ello se hace clic derecho sobre la capa del polígono y después en *Conmutar edición*. Una vez ahí, dentro de la *Barra de digitalización de formas*, podemos clicar en *Añadir polígono*, dentro de la barra de ediciones y trazaremos el rectángulo deseado, que se añadirá a la capa a través de la que cortaremos.

Para realizar el corte, clicaremos en *Procesos* > *Caja de herramientas* > *Cortar ráster por máscara de capa*. Se elige la capa de entrada que se quiera cortar, la capa de máscara será el polígono rectangular y como resolución X e Y se escogerá la mayor entre las dos ortofotografías que se tienen. Además, hay que asegurar que todo está en EPSG:25830.

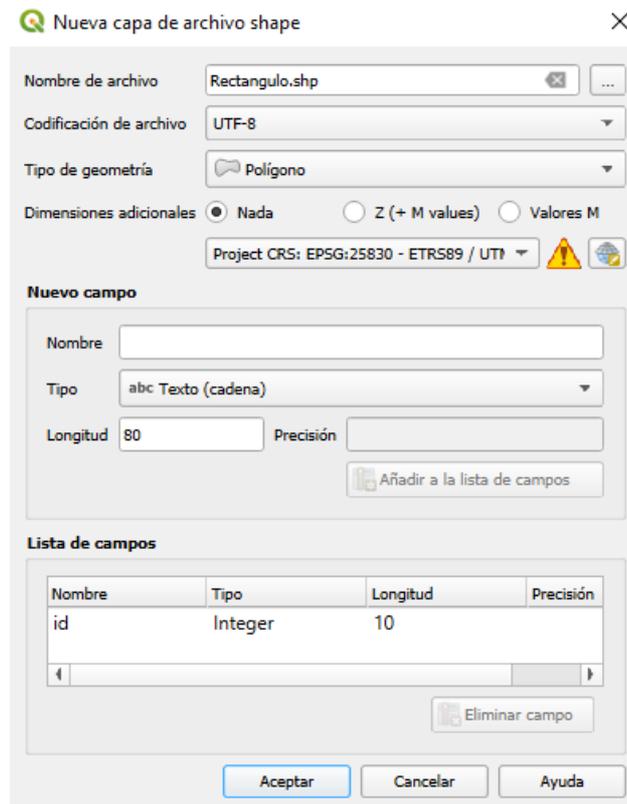


Figura 3-15: Interfaz de creación de *shape* en QGIS®.

### 3.3.2 Instalación de librerías y complementos

Para el tratamiento capas ráster en Python va a ser necesaria la instalación de dos librerías:

- *Rasterio*: Diseñada para trabajar en lectura, escritura y procesamiento de capas ráster. Permite trabajar con conjuntos de datos ráster, modelos digitales de elevaciones y otros datos en cuadrícula [42]. Entre sus utilidades destacan el manejo de proyecciones, la extracción y manipulación de datos, la reproyección de rásters y la obtención de datos propios de las capas ráster para su posterior procesado.
- *Numpy*: Biblioteca orientada al cálculo numérico y tratamiento de grandes conjuntos de datos. También permite la creación de vectores y matrices multidimensionales [44].

La instalación se llevará a cabo mediante el Símbolo del sistema de Windows. Para ello, accedemos escribiendo en el buscador de Windows “cmd”. Habrá que acceder al directorio donde se tenga instalado QGIS® y escribir el comando “python -m pip install rasterio” ó “pyhton -m pip install numpy”.

```

C:\> Símbolo del sistema
Microsoft Windows [Versión 10.0.19045.4170]
(c) Microsoft Corporation. Todos los derechos reservados.

C:\Users\Usuario>cd C:\Program Files\QGIS 3.34.11
C:\Program Files\QGIS 3.34.11>python -m pip install rasterio
  
```

Figura 3-16: Instalación de librería para Python para QGIS®.

Por otro lado, también habrá que instalar el complemento *Semi-Automatic Classification Plugin* (SCP), orientado a la clasificación y detección de cambios en imágenes satelitales o aéreas utilizando algoritmos de ML, tanto supervisados como no supervisados. Para llevar a cabo su instalación, se debe acceder a la interfaz de complementos de QGIS® *Complementos>Administrar e instalar complementos...* y buscar el deseado.

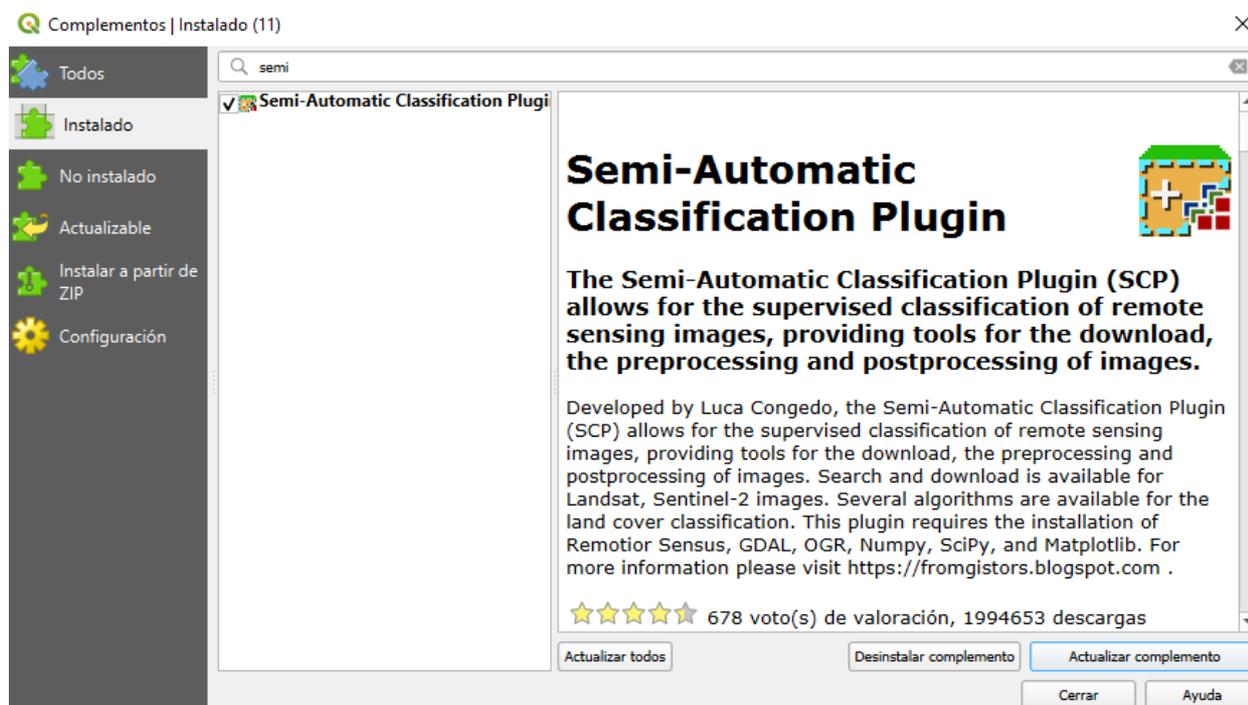


Figura 3-17: Interfaz de instalación de complementos para QGIS®.

### 3.3.3 Creación de ráster de diferencias

Para detectar las potenciales variaciones que hayan podido tener lugar en el terreno durante el tiempo transcurrido entre los dos vuelos, será necesario realizar una diferencia de bandas ráster entre las ortofotografías y/o MDE, para poder tener en un mismo ráster, las bandas de diferencias en RGB y/o alturas.

Para conseguir la diferencia de ráster, se van a utilizar dos métodos.

- Calculadora ráster de QGIS®: Permite realizar operaciones matemáticas en datos ráster de entrada para la obtención de productos derivados sobre ellos. Su funcionamiento consiste en introducir la expresión matemática deseada indicando los ráster con los cuales se va a operar. En nuestro caso, se va a utilizar para combinar capas ráster realizando una operación aritmética de diferencia. En la Figura 3-18, se presenta un ejemplo donde se calcula la diferencia entre las bandas 1 de dos ráster.

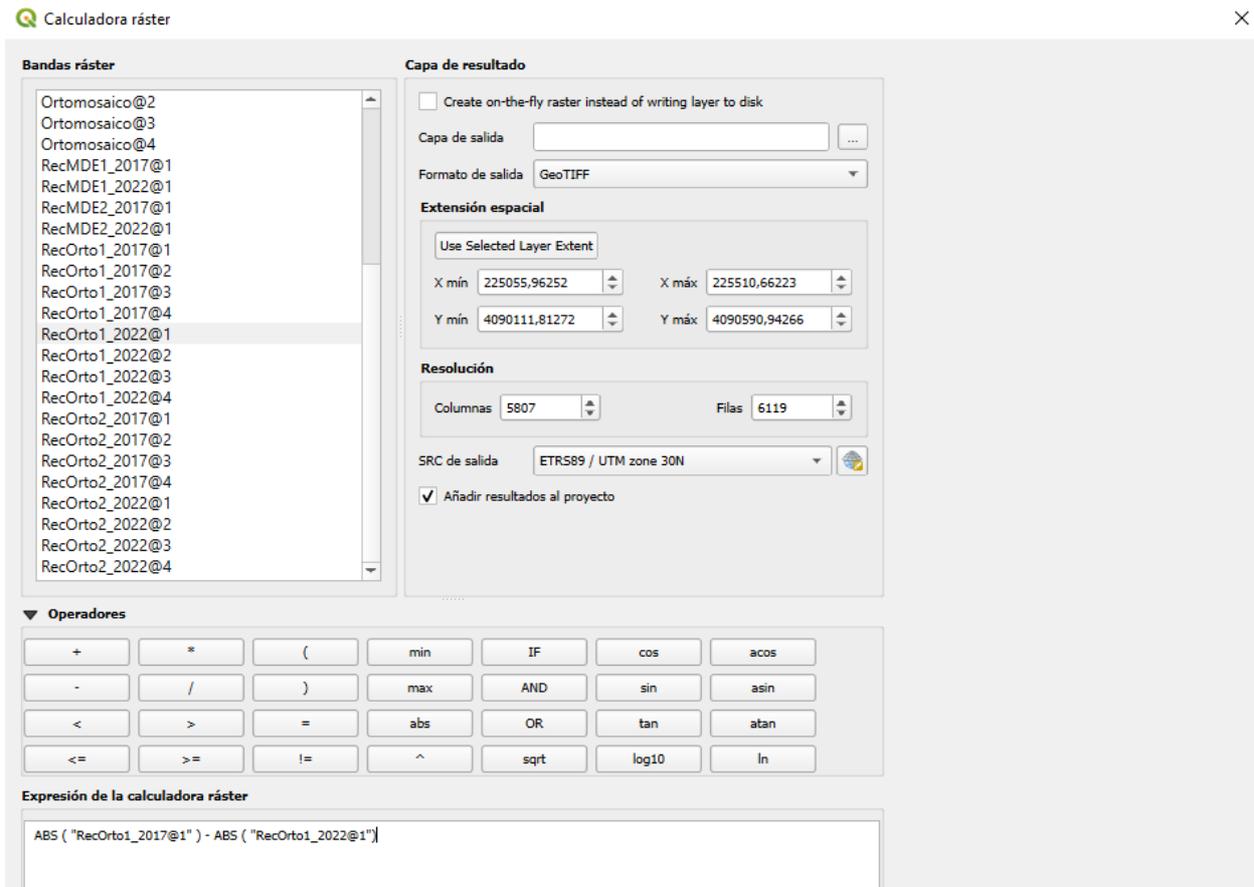


Figura 3-18: Ejemplo de uso de calculadora ráster de QGIS®.

- Codificación en Python: Con el fin de automatizar su obtención y evitar tener que introducir las expresiones repetidamente en la calculadora ráster, y, con soporte de ChatGPT, se va a crear una secuencia de comandos (en inglés *script*), que permite obtener un ráster que contiene en sus bandas, la diferencia de bandas de dos ráster introducidos como datos. Además, se añade una secuencia de comandos que permite clasificar y categorizar los cambios según el valor de su diferencia. El *script* se encuentra completo en el Anexo A para su consulta.

La consola de Python viene integrada en QGIS® y su acceso se encuentra en *Complementos > Consola de Python*.

### 3.3.4 Detección de cambios y salida de datos

Se va a vincular la variación de valores en las bandas de los ráster con la variación real en el terreno sucedida en el periodo transcurrido entre los dos vuelos. La detección de cambios basada en los datos aportados por las imágenes aéreas, también conocida como teledetección, se va a llevar a cabo de dos formas:

- Análisis de variación entre bandas RGB. Con los productos obtenidos del script de Python (ver 3.3.3), se va a realizar un análisis con el fin de discurrir si se pueden encontrar patrones en la variación de colores RGB que puedan indicar variaciones en la vegetación y, que, además, puedan ir ligados a variaciones en altura.
- Utilización de técnicas y algoritmos de ML. Se va a hacer uso del SCP, complemento para QGIS® que permite la clasificación semi-automática, y también supervisada (basada en modelos de entrenamiento) de imágenes para teledetección. Se van a combinar las bandas RGB junto a la del MDE para poder realizar una clasificación más precisa. SCP es un complemento orientado a la clasificación de la cobertura terrestre principalmente, que además posee conexión hacia las imágenes tomadas por el satélite Sentinel 2. También posee herramientas para el procesado de datos ráster para poder desarrollar el flujo de trabajo al completo. La interfaz se muestra en la Figura 3-19.

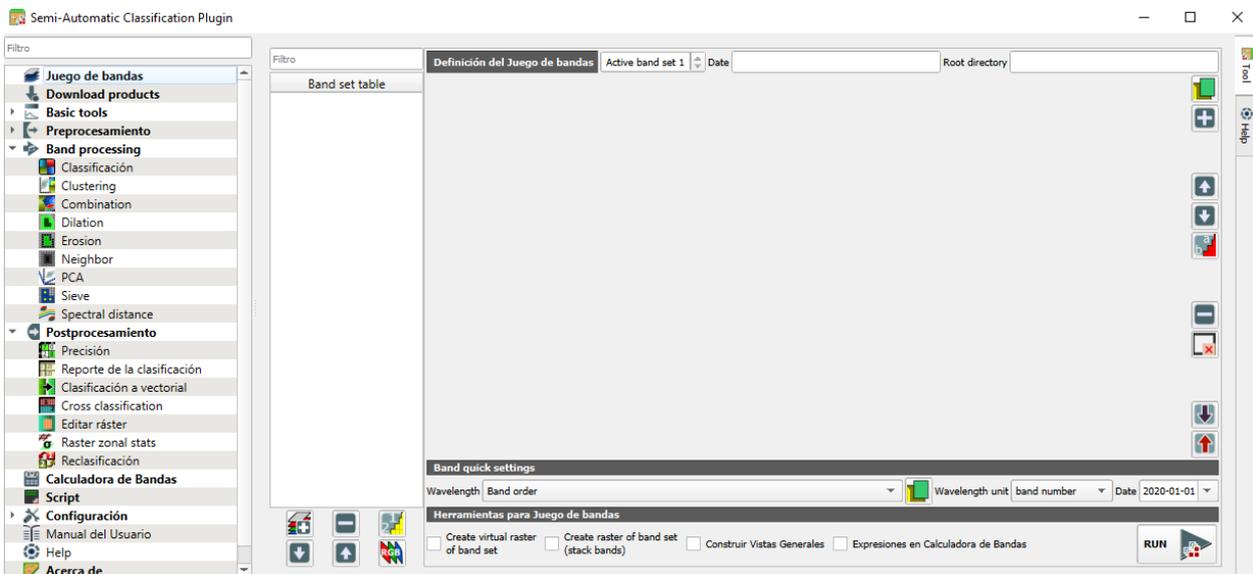


Figura 3-19: Interfaz de uso de SPC para QGIS®.

Tiene integrados algoritmos de aprendizaje automático como el de bosque aleatorio o el de agrupamiento (en inglés *-clustering-*), que será, principalmente, el utilizado en este TFM.

El *clustering* es un método no supervisado de ML, basado en el agrupamiento de píxeles que posean la misma firma espectral, que es el conjunto de longitudes de onda emitidas o reflejadas por la superficie de un objeto, calculado para una imagen multispectral. Su principal ventaja reside en la capacidad de automatización del método una vez se hallan los valores precisos para sus parámetros [43].

El algoritmo utilizado en este método es el *K-means*, que se basa en el cálculo de la firma media espectral para conseguir grupos de clasificación. El algoritmo comienza eligiendo aleatoriamente un número determinado por el usuario de firmas espectrales. En la primera iteración, clasifica los píxeles por su distancia a dichas firmas. Una vez hecha esta primera iteración, al pasar a la segunda, calcula la firma espectral media de los primeros agrupamientos que ha realizado, volviendo a clasificar entonces según la distancia espectral a las firmas espectrales de la iteración anterior. El método continúa iterando hasta que la distancia espectral de las firmas de esa enésima iteración dista menos de un cierto umbral definido por el usuario con respecto a la anterior iteración o hasta que se alcanza el número máximo de iteraciones definido por el usuario es alcanzado.

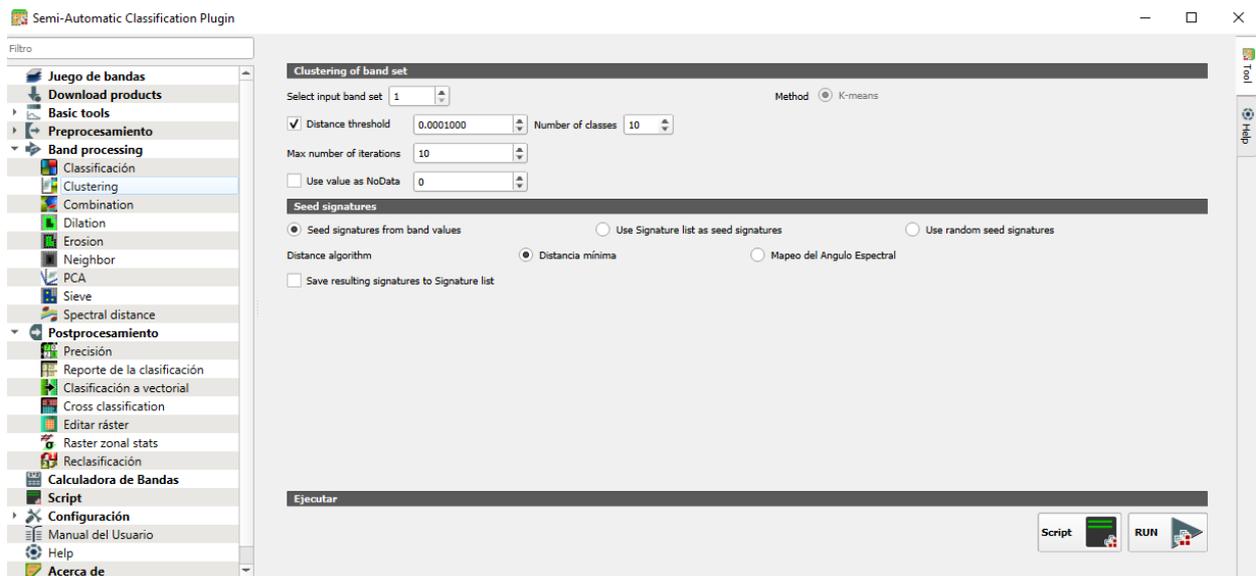


Figura 3-20: Interfaz de uso de algoritmo de *clustering* en SCP para QGIS®.

Para la realización del *clustering* se requiere la elección de algunos parámetros, como se muestra en la Figura 3-20. A continuación, se procede con su explicación:

- *Distance threshold* (en español –distancia umbral-): la iteración termina cuando la distancia de la firma espectral del píxel a clasificar con respecto a la firma espectral que esté usando el algoritmo para clasificar sea menor que cierto número umbral.
- *Max number of iteration* (en español –máximo número de iteraciones-): Número máximo de veces que iterará el clasificador si aún no se ha alcanzado la distancia umbral antes de parar.
- *Number of classes* (en español –número de clases-): Es el número diferente de clases que dará el clasificador como salida.
- *Seed signatures* (en español –firmas espectrales semilla-): Son las firmas espectrales con las que se realizará la primera iteración.
- *Distance algorithm* (en español –algoritmo de distancia-): Algoritmo utilizado para calcular la distancia entre firmas espectrales.

Para finalizar, al ráster resultado del *clustering* se les va a aplicar un filtro de reducción de ruido, para minimizar los píxeles aislados mal clasificados y conseguir una clasificación más homogénea. Para ello, se va a utilizar un *script* de Python que aplica un filtro de media móvil, que reemplaza el valor de cada píxel con el promedio de sus píxeles vecinos, reduciendo así el ruido que puedan inducir píxeles clasificados de forma aislada a sus vecinos.



# 4 RESULTADOS

## 4.1 Levantamiento fotogramétrico en Agisoft Metashape®

Una vez realizado el proceso descrito en la sección 3.2 y siguiendo los pasos del diagrama de flujo contenido en la Figura 3-1, se van a presentar los resultados obtenidos.

La carga, orientación y establecimiento de SRC ETRS89 / UTM zona 30N (EPSG:25830), se lograron de forma satisfactoria, teniendo así el conjunto de fotografías disponible para la identificación de puntos de control y el añadido de máscaras en los casos que apliquen.

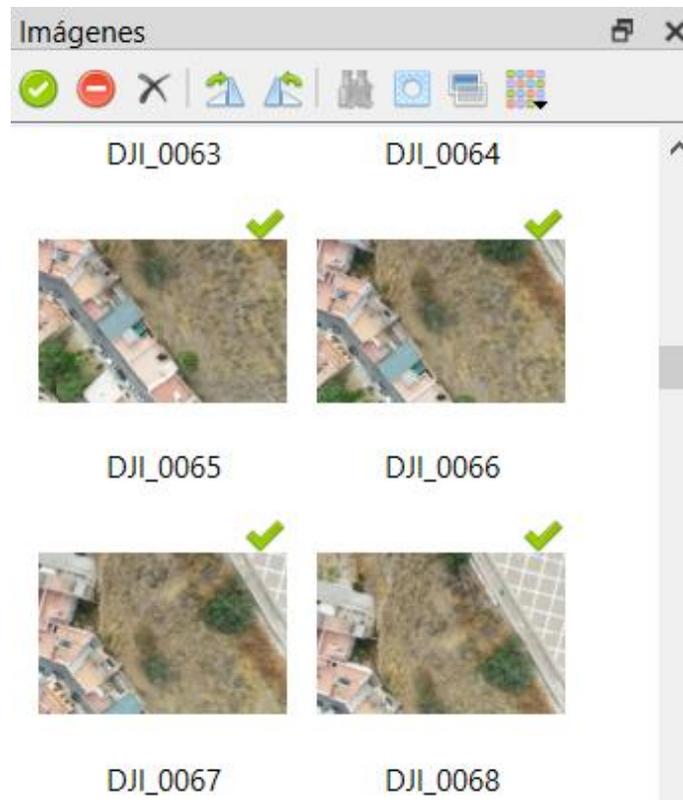


Figura 4-1: Muestra de fotografías cargadas en interfaz de Metashape®.

Al realizar la orientación de las fotografías, se generó la nube de puntos dispersa, que representa los puntos clave que Metashape® ha identificado en cada fotografía y que son coincidentes en diferentes imágenes.

Teniendo en cuenta que se estableció una precisión *Alta* para su generación, esta nube proporciona una visión preliminar del modelo tridimensional buscado. En la Tabla 4-1 se pueden observar sus características principales.

Tabla 4-1: Características principales de la nube de puntos dispersa.

Nube de puntos dispersa	Resultado
Puntos clave por foto	40,000
Puntos de paso	414,159
Tiempo de procesado	27 minutos

Como se aprecia en las Figuras 4-2 y 4-3, se tiene una nube que, aunque es carente de densidad, sirve para estimar la orografía.



Figura 4-2: Nube de puntos dispersa generada en la Zona 1 de estudio en Metashape®.

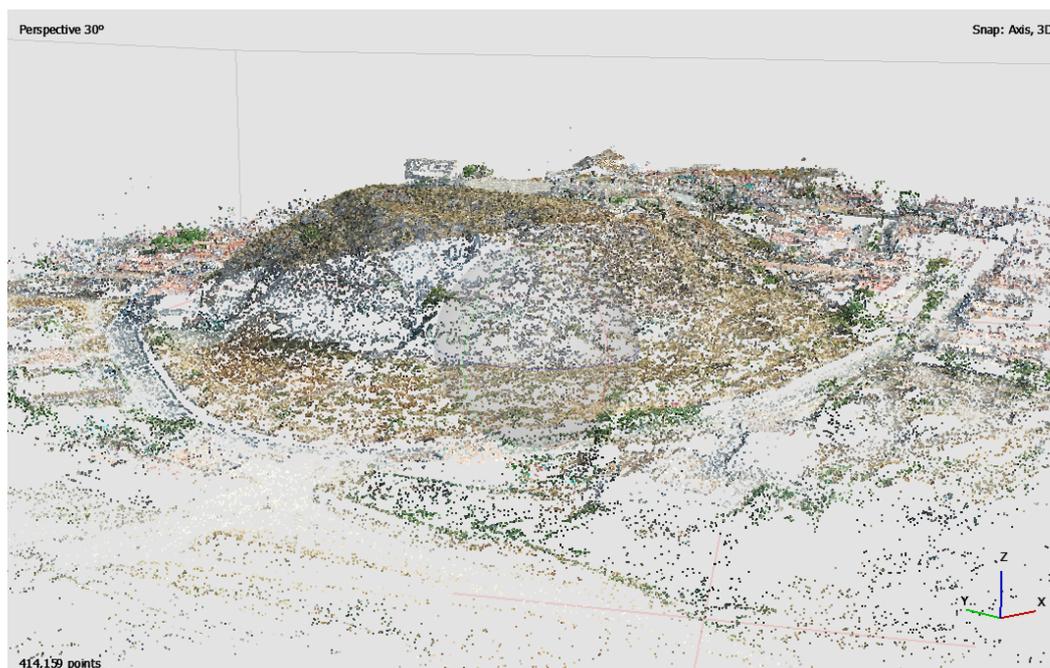


Figura 4-3: Nube de puntos dispersa generada en la Zona 2 de estudio en Metashape®.

Con las fotografías cargadas en el proyecto, se pudo continuar con la importación de los puntos de control. Haciendo coincidir el formato con el especificado en el programa, y teniendo los puntos de control en EPSG:25830, se ve cómo algunos de puntos de control aparecen directamente en las fotografías de forma automática. Cabe destacar que esta primera aproximación (ver Figura 4-4) que hace Metashape® no tiene por qué ser precisa, de hecho, en la mayoría de ocasiones los puntos de control aproximados suelen distar bastante de los puntos de control reales. Cuando se van verificando los puntos de control manualmente, la aproximación se va afinando, llegando a coincidir o estando bastante cerca de la realidad.



Figura 4-4: Primera aproximación de PC9 y PC10 realizada por Metashape® al cargar las coordenadas de los PC.

El número de proyecciones de un punto de control es el número de veces que ha podido ser verificado en las fotografías aéreas tomadas por el dron. Un mayor número de proyecciones da lugar a obtener un menor error en la ubicación del punto de control con respecto a la realidad. Se considera una buena muestra de proyecciones tener 10 por cada punto de control. En este proyecto, la media de proyecciones por PC es de 25 y se tienen 10 puntos de control con menos de 10 proyecciones, ya que no se pudieron verificar más proyecciones debido a falta de ángulos de fotografía.

Debido a la naturaleza de algunos puntos de control, situados en elementos móviles o de baja visibilidad (ver Figuras 4-5 y 4-6), de los 71 puntos de control proporcionados como dato para el proyecto, no todos pudieron ser referenciados hacia las fotografías en Metashape. En la Tabla 4-2 se realiza un desglose de la validez de los PC.

Tabla 4-2: Desglose de validez de Puntos de Control.

	Válidos	No válidos	Total
Zona 1	42	5	47
Zona 2	17	7	24
			71



Figura 4-5: Punto de control 36 (Zona 1) rechazado debido a imposibilidad de encontrarlo en las imágenes aéreas.



Figura 4-6: Proyección de PC válida (izquierda) en comparación proyección no válida del mismo PC por falta de visibilidad (derecha). Metashape®.

En los PC existe un error, explicado como la diferencia entre las coordenadas de los PC en la realidad con respecto a las coordenadas en el modelo fotogramétrico. Para disminuir el error en los PC, se utiliza la *optimización de cámaras*, que fuerza a que el error disminuya al valor mínimo posible. Por tanto, una vez verificados el mayor número posible de puntos de control, se aplicó la optimización de cámaras, consiguiendo los valores de error mostrados en la Tabla 4-3.

Tabla 4-3: Resultados obtenidos en error para los puntos de control en el proyecto.

Parámetro de error	Resultado (m)
Error medio total	0.091
Error mediano total	0.038
Máximo error en PC	1.01
Mínimo error en PC	0.004

Tras realizar la verificación de los puntos de control y su optimización, en la Figura 4-7 se muestra la nube de puntos dispersos y la proyección de los PC del modelo completo.

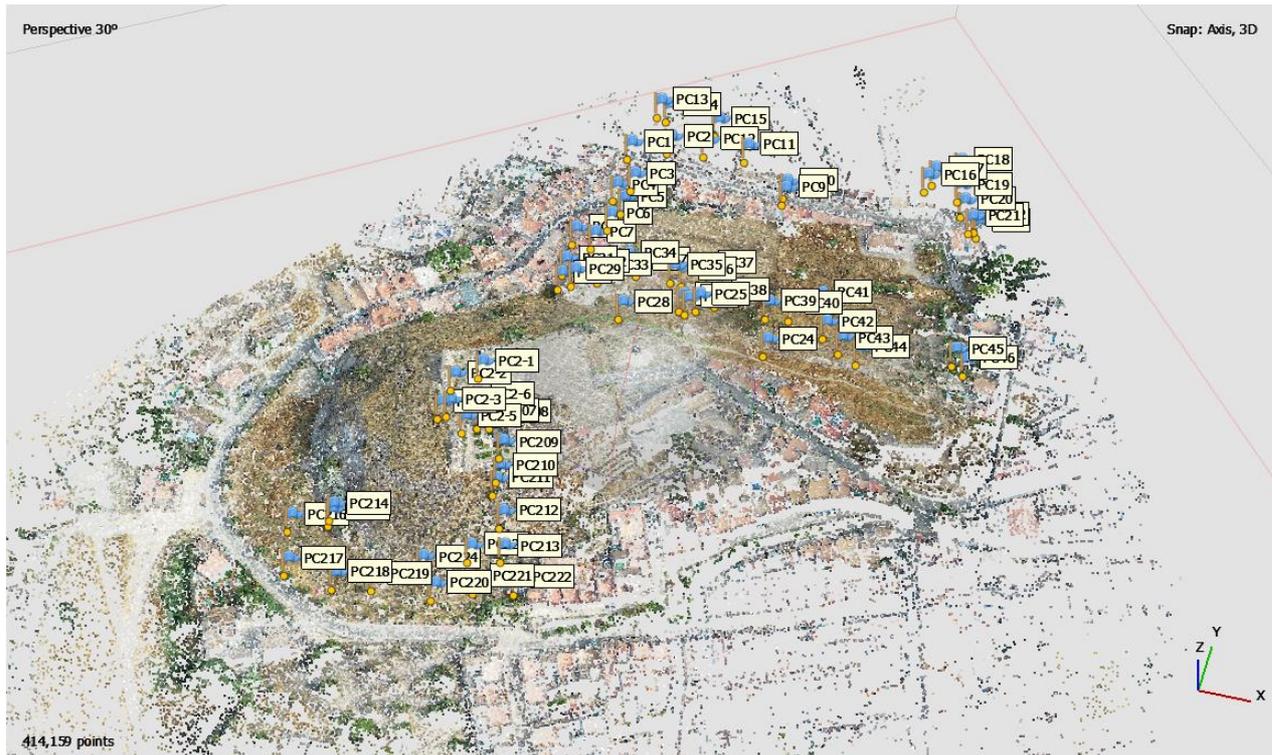


Figura 4-7: Nube de puntos dispersos y proyección de puntos de control en Metashape.

A partir de la nube de puntos dispersa y de los PC se construyó la nube de puntos densa. Cabe destacar que, la continuación de pasos a seguir dentro del flujo de trabajo se realizó en el ordenador secundario de la ETSIA (ver sección 2.5.), ya que con el ordenador principal no se consiguió terminar el proceso de generación de la nube de puntos densa, al fallar éste en varias ocasiones por falta de memoria cuando llevaba procesando 12 horas. Sin embargo, con el ordenador secundario, con una capacidad de procesamiento gráfico y memorias muy superiores, se consiguió obtener la nube de puntos densa en 44 minutos.

Con la nube de puntos densa, tal y como se muestra en las Figuras 4-8 y 4-9, ya se tiene un modelo tridimensional detallado que representa fielmente a la realidad la orografía.

Tabla 4-4: Características principales de la nube de puntos densa generada en Metashape®.

Nube de puntos densa	Resultado
Número de puntos	39,918,625
Tiempo de procesado	44 minutos



Figura 4-8: Nube de puntos densa generada en la Zona 1 en Metashape®.



Figura 4-9: Nube de puntos densa generada en la Zona 2 en Metashape®.

Continuando con el flujo de trabajo (ver Figura 3-2), se obtuvo la malla a partir de la nube de puntos densa. Como se detalló en la subsección 3.2.3, la creación de la malla implica la unión de los puntos de la nube con polígonos, consiguiendo así una estructura más robusta del modelado. Ya que dentro de la zona de estudio se tienen diferentes tipos de superficies de terreno, como árboles, arbustos, construcciones, carretera, zonas montañosas, etc. Se optó por realizar un mallado arbitrario, ya que es la mejor opción que tiene el software de obtener unos mejores resultados generales. En la Tabla 4-5 se muestran sus características.

Tabla 4-5: Características del mallado generado en Metashape®.

Mallado	Resultado
Número de caras	6,605,244
Número de vértices	3,306,869
Tiempo de procesado	19 min

El resultado se muestra en las Figuras 4-10 y 4-11:



Figura 4-10: Mallado obtenido en la Zona 1 de estudio en Metashape®.



Figura 4-11: Mallado obtenido en la Zona 2 de estudio en Metashape®.

Para conseguir una representación del terreno en tres dimensiones más precisa, se le aplica un texturizado a la malla, lo que creará un aspecto más visual, detallado y continuo sobre ella. La información visual aportada por la textura ayuda a que el modelo tridimensional se vea de una forma más natural y similar al propio terreno en la realidad. En las Figuras 4-12 y 4-13 se muestra el resultado obtenido para las zonas 1 y 2 de estudio en el vuelo sobre Lebrija.



Figura 4-12: Texturizado obtenido en la Zona 1 de estudio en Metashape®.



Figura 4-13: Texturizado obtenido en la Zona 2 de estudio en Metashape®.

A continuación, se muestra una comparativa entre el modelo texturizado y el modelo mallado. En todas las comparativas se observa que el modelo texturizado representa más detalladamente el perfil y la superficie de los objetos visibles, con una mayor nitidez y sus colores son más fidedignos a la realidad.



Figura 4-14: Comparativa de representación de vegetación alta en modelo texturizado (arriba) con respecto a modelo mallado (abajo) generados en Metashape®.

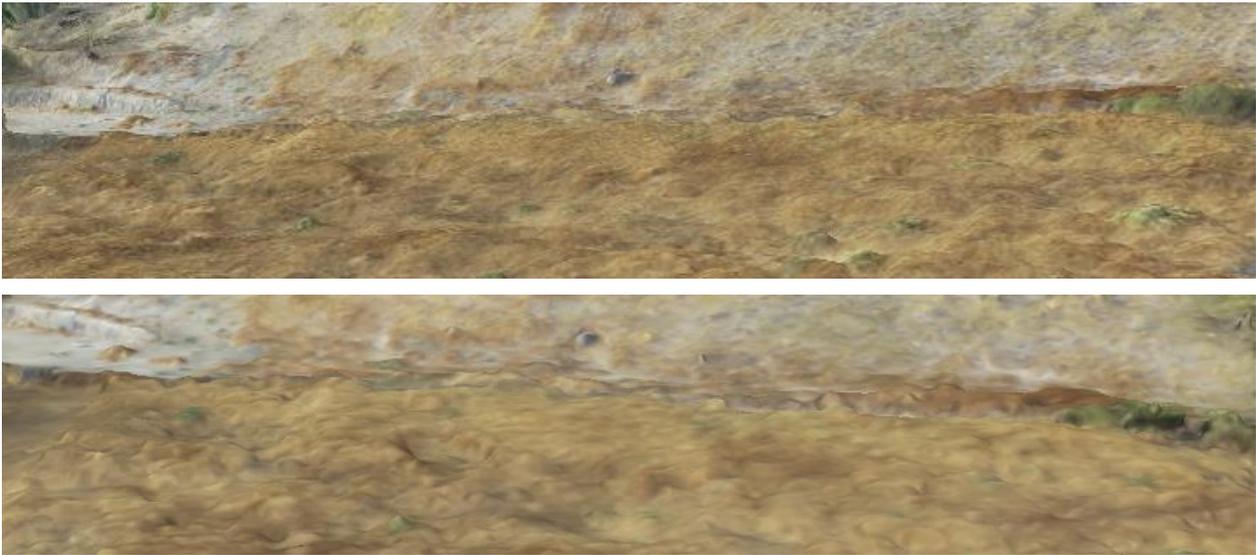


Figura 4-15: Comparativa de representación de vegetación baja en modelo texturizado (arriba) con respecto a modelo mallado (abajo) generados en Metashape®.

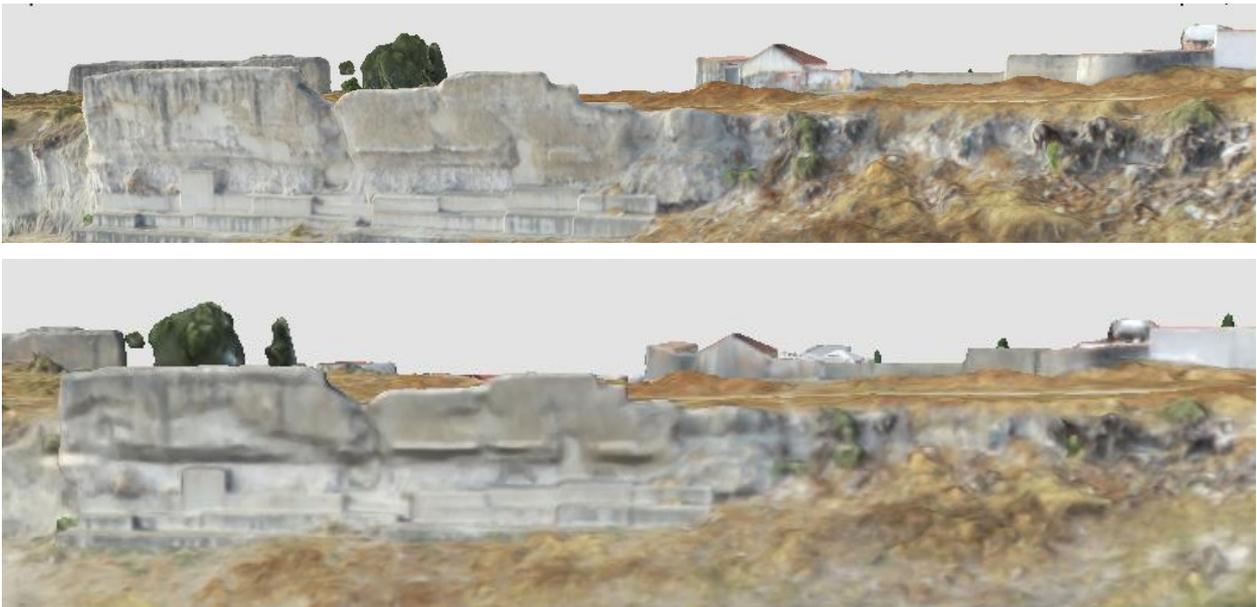


Figura 4-16: Comparativa de representación de zonas rocosas en modelo texturizado (arriba) con respecto a modelo mallado (abajo) generados en Metashape®.





Figura 4-17: Comparativa de representación de una edificación en modelo texturizado (arriba) con respecto a modelo mallado (abajo) generados en Metashape®.

A partir de la nube de puntos densa, se procedió a generar el Modelo Digital de Elevaciones, cuyo resultado se muestra en la Figura 4-18. En la Tabla 4-6 se presentan sus principales características.

Tabla 4-6: Características principales del MDE generado en Metashape®.

MDE	Resultado
Origen de datos	Nube de puntos densa
Tamaño	5,808 x 6,120
SRC	ERTS89 / UTM Zone 30 (EPSG: 25830)
Tiempo de procesado	10 segundos

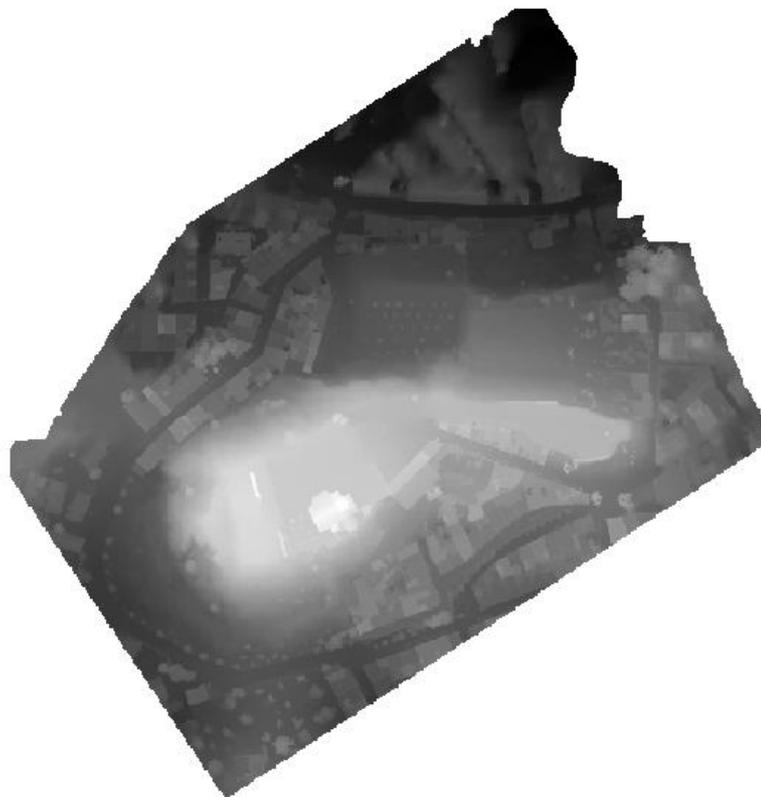


Figura 4-18: Modelo Digital de Elevaciones generado para la zona de estudio al completo obtenido en Metashape®.

Finalmente, a partir del MDE se obtiene la ortofotografía de la zona de estudio (Figura 4-19). Posee unas dimensiones de 23231 x 24474 píxeles.



Figura 4-19: Ortofotografía de la zona de estudio al completo obtenida en Metashape®.

Cabe destacar que tanto el MDE como la Ortofotografía se han exportado en formato \*.tif, específico para almacenar imágenes de mapa de bits, y compatible con QGIS®.

## 4.2 Detección de cambios superficiales en el terreno mediante ML

### 4.2.1 Análisis según variación en bandas RGB

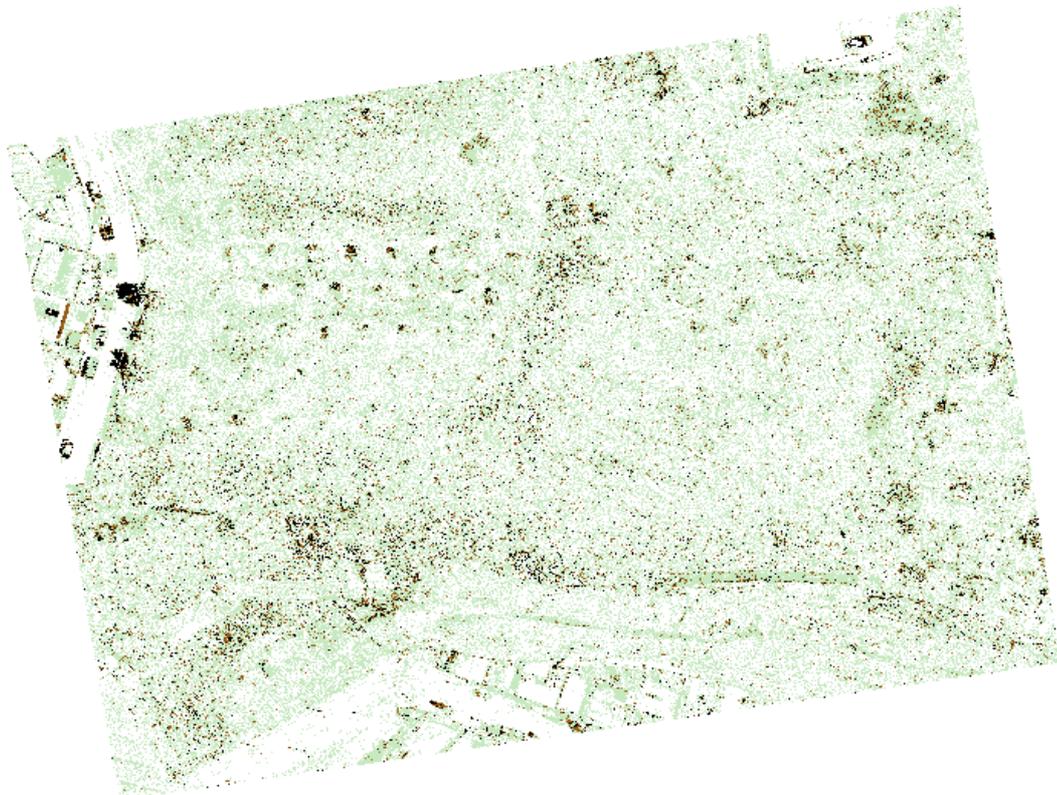
Como primera toma de contacto, se testeó la posibilidad de detectar variaciones en el terreno a partir de la creación de un ráster que sea resultado de la diferencia de los ráster de las ortofotografías de 2017 y 2022. Debido a que la superficie del terreno de estudio está, en general, cubierta por vegetación, se decidió sólo tener en cuenta la banda *Green* (verde en español), ya que por definición es la que más información contendrá sobre variaciones en la vegetación, pudiendo llevar asociadas también variaciones en altitudes.

Mediante un *script* codificado en Python para QGIS® (ver en Anexo A), se creó el ráster de diferencias de las bandas verdes de las ortofotografías de 2017 y 2022. La ecuación (5-1) muestra la expresión matemática utilizada para crear dicho ráster. Los valores RGB se mueven en el intervalo [0, 255], por tanto, el valor máximo de los píxeles queda así en 255.

$$\text{ráster diferencia}_{\text{banda verde}} = \text{abs}(\text{Ortofoto2017}_{\text{banda verde}} - \text{Ortofoto2022}_{\text{banda verde}}) \quad (5-1)$$

El resultado obtenido se presenta en la Figura 4-20. Aunque el *script* de Python diferenciaba 5 categorías diferentes de clasificación, manualmente se realizó una clasificación de 4 categorías, tras el estudio del histograma del ráster obtenido (ver Figura 4-21), ya que el valor máximo presente se encontraba en torno a 160.

A continuación, se realizará el análisis de algunas zonas del ráster de diferencias para ayudar a la interpretación de los resultados.



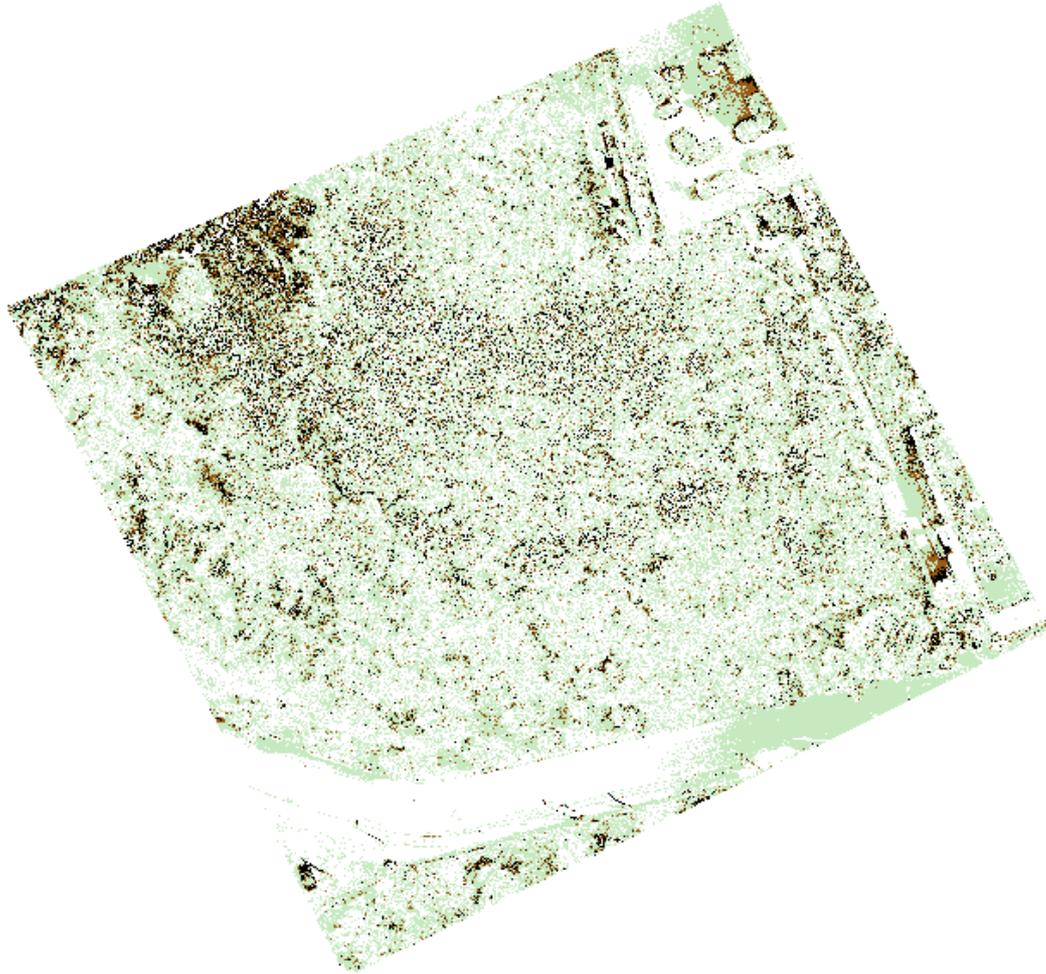


Figura 4-20: Ráster de diferencias obtenido mediante *script* de Python para QGIS® para las zonas 1 (arriba) y 2 (abajo).

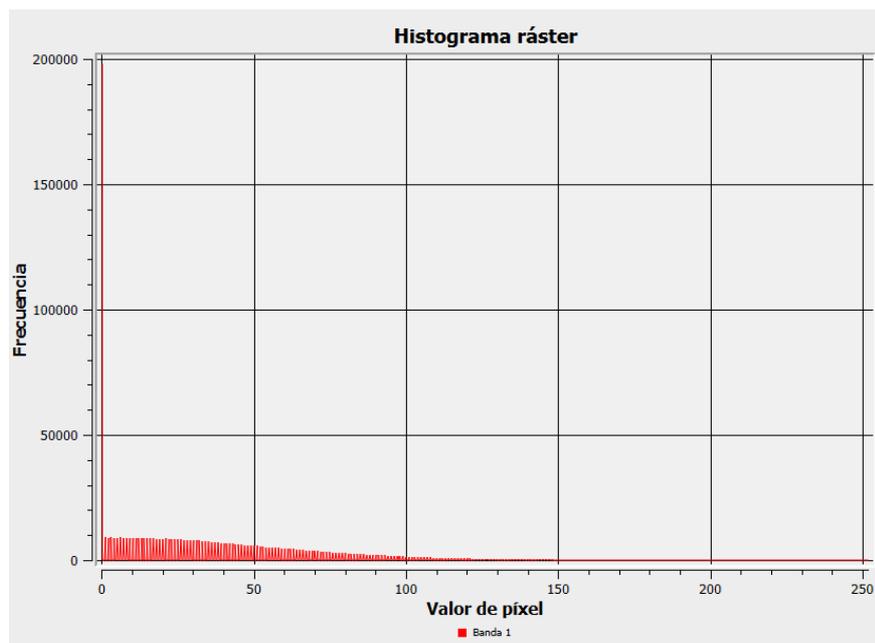


Figura 4-21: Histograma obtenido en el ráster de diferencias en QGIS®.

Se ha podido diferenciar una clasificación en 4 categorías según los valores ráster se puede ver en la Figura 4-22:

Valor <=	Color	Etiqueta
40		Sin cambios apreciables
100		Cambios vegetación media
120		Cambios vegetación alta
160		Zona de Sombras

Figura 4-22: Clasificación realizada en ráster de diferencias.

Tomando como muestra el fragmento presentado en la Figura 4-23, usando de apoyo a la explicación las ortofotos originales, se puede observar que se tienen bien diferenciadas las zonas de sombras, ya que en la ortofoto de 2017 existe una sombra muy fuerte que no está presente en 2022, por lo que, al ser una diferencia tan grande en el valor de los píxeles en esa zona, se destaca fácilmente su clasificación. Además, los árboles en 2017 también proyectan una sombra fuerte, reflejada también en el ráster.

En cuanto a los cambios de vegetación media, entre 2017 y 2022 se observa el cambio desde una vegetación verde baja hacia una vegetación de color marrón árido, por lo que, se tiene una proyección de color verde en toda esa superficie, salvando las zonas donde existen claros de tierra, donde el resultado es de un color blanco indicando que apenas hay variación en la banda verde.

Por último, se observan pequeñas muestras de color marrón, que indican variaciones en la vegetación alta, principalmente en las copas de los árboles. Se destaca en la zona de la izquierda, donde se tienen 3 árboles que son talados desde 2017 a 2022. La clasificación muestra esta variación coloreando de verde y marrón principalmente el cambio, aunque también existe una zona de sombra fuerte, justificada con la fotografía de 2017. Además, se observa también que en los árboles del centro y derecha de las imágenes también se tienen puntos marrones, indicando en este caso que existe variación, aunque en este caso, del propio color verde de los árboles, ya que se encuentran presentes en ambas fotografías aéreas, lo que podría indicar diferencias debido a un estado de salud o por la época estacional de la planta.

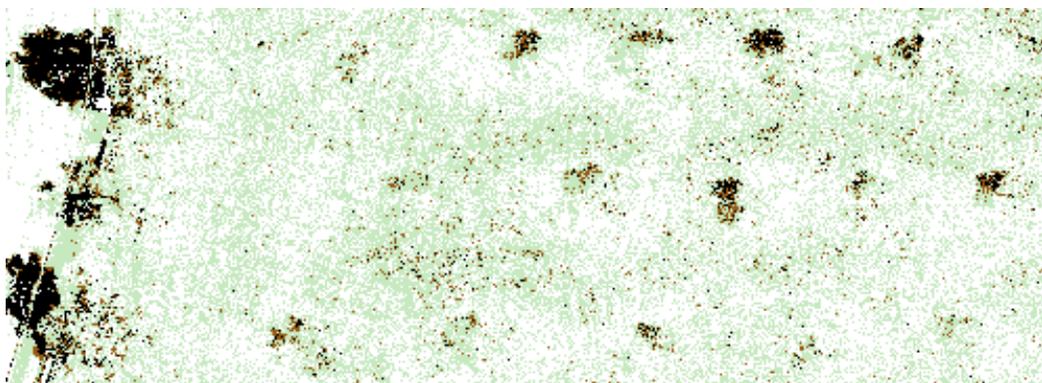




Figura 4-23: Fragmento de ráster de diferencias (arriba), orto 2017 (medio) y orto 2022 (abajo) para la Zona 1.

Atendiendo a la zona 2 de estudio, se va a realizar un análisis similar al anterior. En la Figura 4-24, se presenta un fragmento del ráster de diferencias y de las dos ortofotos. En ellos se observa como una zona de matorrales se ha secado completamente entre 2017 y 2022. La clasificación nos muestra la zona en colores verdes claros y marrones, indicando la variación de color verde hacia grises. También se observan zonas de sombra clasificadas en negro debido a la propia sombra proyectada por los matorrales.





Figura 4-24: Fragmento de ráster de diferencias (arriba), orto 2017 (abajo izquierda) y orto 2022 (abajo derecha) para la Zona 2.

#### 4.2.2 Detección de cambios mediante SCP

Para abordar este apartado, se aprovechó que se tiene el modelo digital de elevaciones ligado a las ortofotografías para la creación de un apilamiento o *stack* de bandas que uniera las tres RGB junto a la de altitudes del MDE. Para ello, además de tener georreferenciadas al mismo sistema (EPSG: 25830) todos los datos ráster, las dimensiones de las imágenes ráster deben ser las mismas y la resolución, para evitar problema de compatibilidad, también, por lo que se deberá adaptar la resolución de las ortofotografías y los MDE a la mayor de todas.

Por tanto, habrá que adaptar nuestros datos de entrada (ortofotos y MDE) a una resolución y medidas comunes entre ellas para poder realizar el *stack*. Se realizó mediante el corte de ráster por capa de máscara en QGIS®, procedimiento explicado en el apartado 3.3.1. Las medidas y resolución de la fotografía se recogen en la Tabla 4-7:

Tabla 4-7: Resolución y tamaño de ortofotos y MDE adaptados para realizar el apilamiento.

		Resolución	Tamaño
Zona 1	Ortofotografía 2017 y 2022	0.08 m/píxel	2335 x 1780 píxeles
	MDE 2017 y 2022	0.08 m/píxel	2335 x 1780 píxeles
Zona 2	Ortofotografía 2017 y 2022	0.08 m/píxel	1655 x 1557 píxeles
	MDE 2017 y 2022	0.08 m/píxel	1655 x 1557 píxeles

Para el *stack* de las bandas se ha utilizado un *script* en Python, que da lugar a dos ráster de 4 bandas (3 RGB y 1 MDE), con la resolución y tamaño por zonas igual a las presentadas en la Tabla 4-7 y con SRC EPSG: 25830. El *script* se puede consultar en el Anexo A.

A continuación, se creará un ráster de diferencia para cada una de las 4 bandas. Se realizará mediante la calculadora ráster y se seguirá la ecuación (5-2):

$$\text{ráster diferencia}_{\text{banda } x} = \text{abs}(\text{stack2017}_{\text{banda } x} - \text{stack2022}_{\text{banda } x}) \quad (5-2)$$

Por tanto, y como se tienen 2 zonas y 4 bandas por ráster, se obtendrán 8 ráster de 1 banda. Para mayor claridad, se presenta en la Tabla 4-8 cómo quedan los ráster de diferencia.

Tabla 4-8: Productos ráster obtenidos tras la diferencia de *stacks*.

Ráster	
Zona 1	Diferencia bandas 1 (2017-2022)
	Diferencia bandas 2 (2017-2022)
	Diferencia bandas 3 (2017-2022)
	Diferencia bandas 4 (2017-2022)
Zona 2	Diferencia bandas 1 (2017-2022)
	Diferencia bandas 2 (2017-2022)
	Diferencia bandas 3 (2017-2022)
	Diferencia bandas 4 (2017-2022)

Una vez obtenidos los ráster de diferencia, se cargarán en el SCP, tal y como se muestra en la Figura 4-25. Cabe destacar que, por defecto, SCP asigna el centro de longitud de onda en valores consecutivos. En nuestro caso, se vio que separando las diferencias en banda 4 (las referentes al MDE), se conseguían mejores resultados, al ser una banda de diferente tipo con respecto a las RGB, teniéndola así más desacoplada a ellas.

Además, los valores de diferencias de bandas de RGB se encuentran en el rango [0, 255] y el mayor delta de alturas se encuentra en un rango inferior a 15 metros. Por tanto, se aplica un factor multiplicativo de 25, para igualar e incluso superar las magnitudes RGB. Se recuerda que en este análisis mediante SCP, se quiere dar un mayor peso a la banda referida al MDE, por lo que este factor multiplicativo también posee este objetivo.

Cabe destacar que, los valores tomados para el centro de longitud de onda y factor multiplicativo no han sido elegidos aleatoriamente, sino que, tras realizar diferentes pruebas de ensayo-error, se ha determinado que eran los que mostraban unos resultados precisos y válidos.

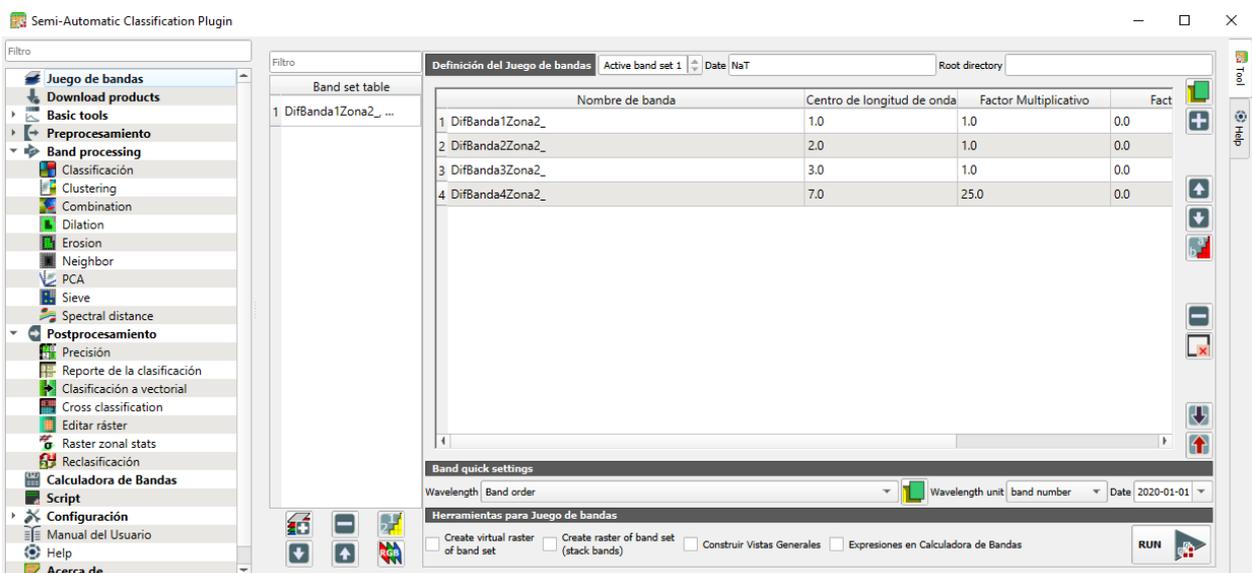


Figura 4-25: Carga de bandas en SCP.

Una vez se tienen las bandas cargadas en el complemento, se procede a realizar el procesado para la obtención del *clustering* (ver Figura 4-26). Se tienen diferentes parámetros que aplican al proceso, y, al igual que en la carga de bandas, su valor escogido no es aleatorio, sino que han sido determinados mediante pruebas ensayo-error. Se recuerda que el algoritmo utilizado en este procesado de bandas *clustering* es el *K-means*, explicado en el apartado 3.3.4.

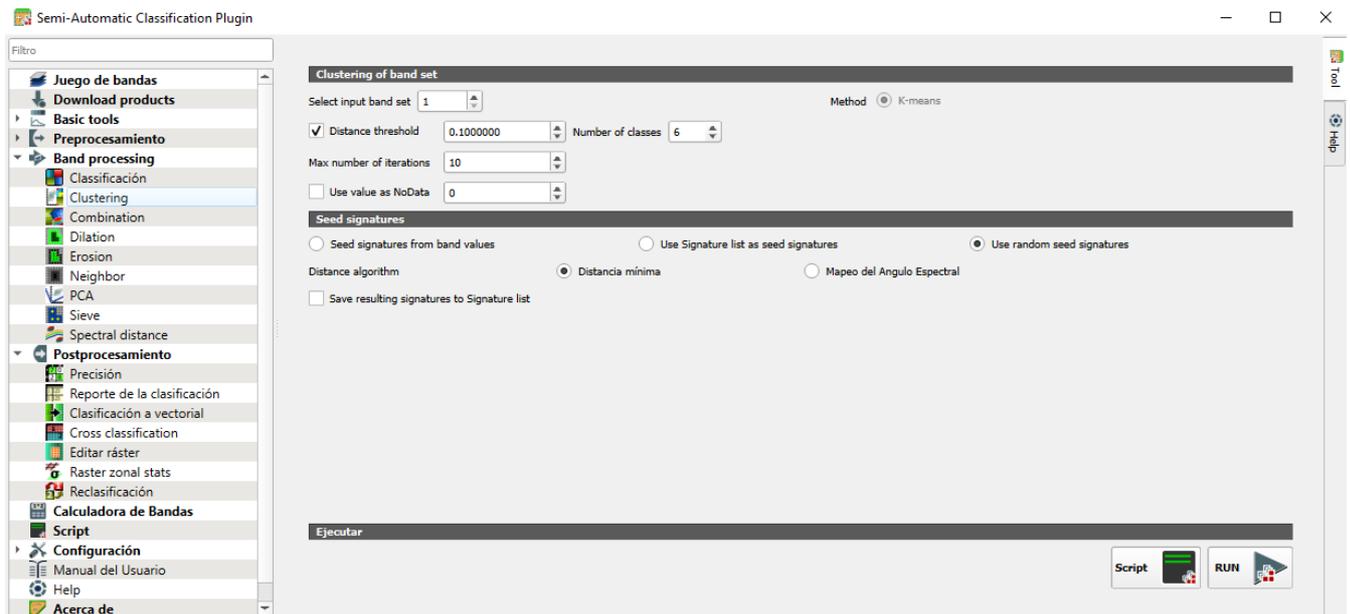


Figura 4-26: Generación de clasificación tipo *clustering* en SCP.

La elección de parámetros escogidos para este *clustering*, explicados en la sección 3.3.4, se recoge en la Tabla 4-9:

Tabla 4-9: Parámetros elegidos en la realización del *clustering* en SCP.

Parámetro	Valor
<i>Distance threshold</i>	0.1
Number of classes	6
Max number of iterations	10
Seed signature	Aleatorias
Distance algorithm	Distancia mínima

El área a analizar será de 20,080 m<sup>2</sup> para la zona 1 y de 9,246 m<sup>2</sup> para la zona 2.

Los resultados obtenidos en el *clustering* realizado sobre las zonas de estudio 1 y 2 se presentan en las Figuras 4-27 y 4-28. Posterior a su obtención, se han sometido a filtrado de ruido, para conseguir la eliminación de los píxeles aislados dentro de conjuntos de píxeles de diferente tipo.

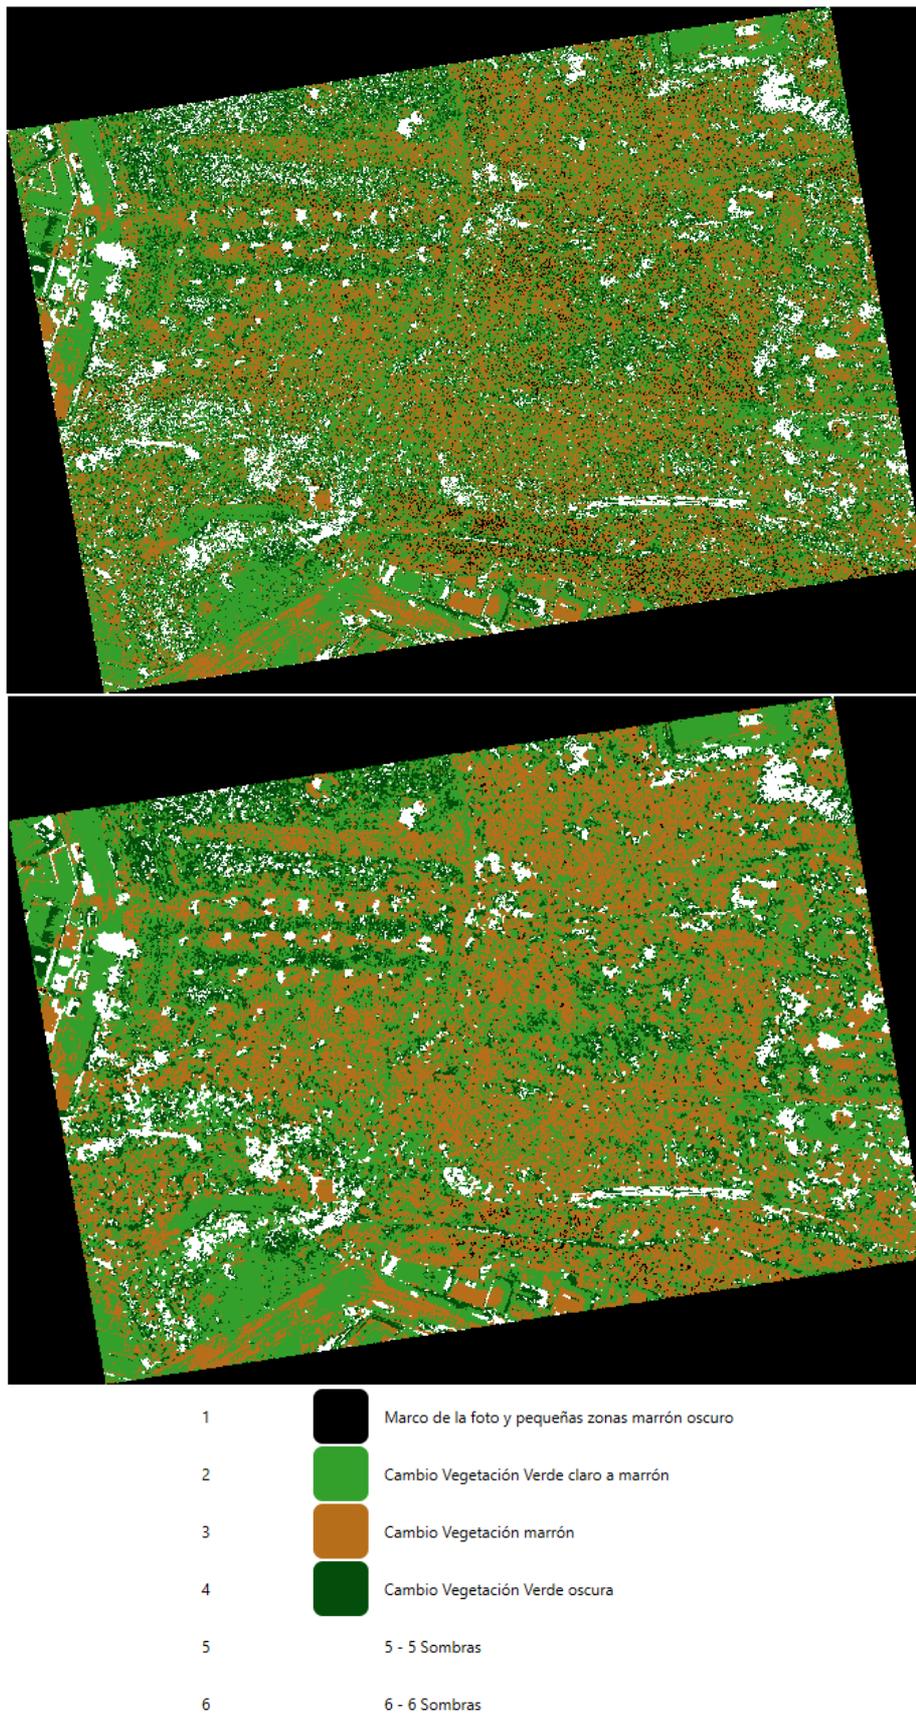


Figura 4-27: *Clustering* obtenido para la Zona 1, sin filtrar (arriba), filtrado (medio) y leyenda de colores (abajo).

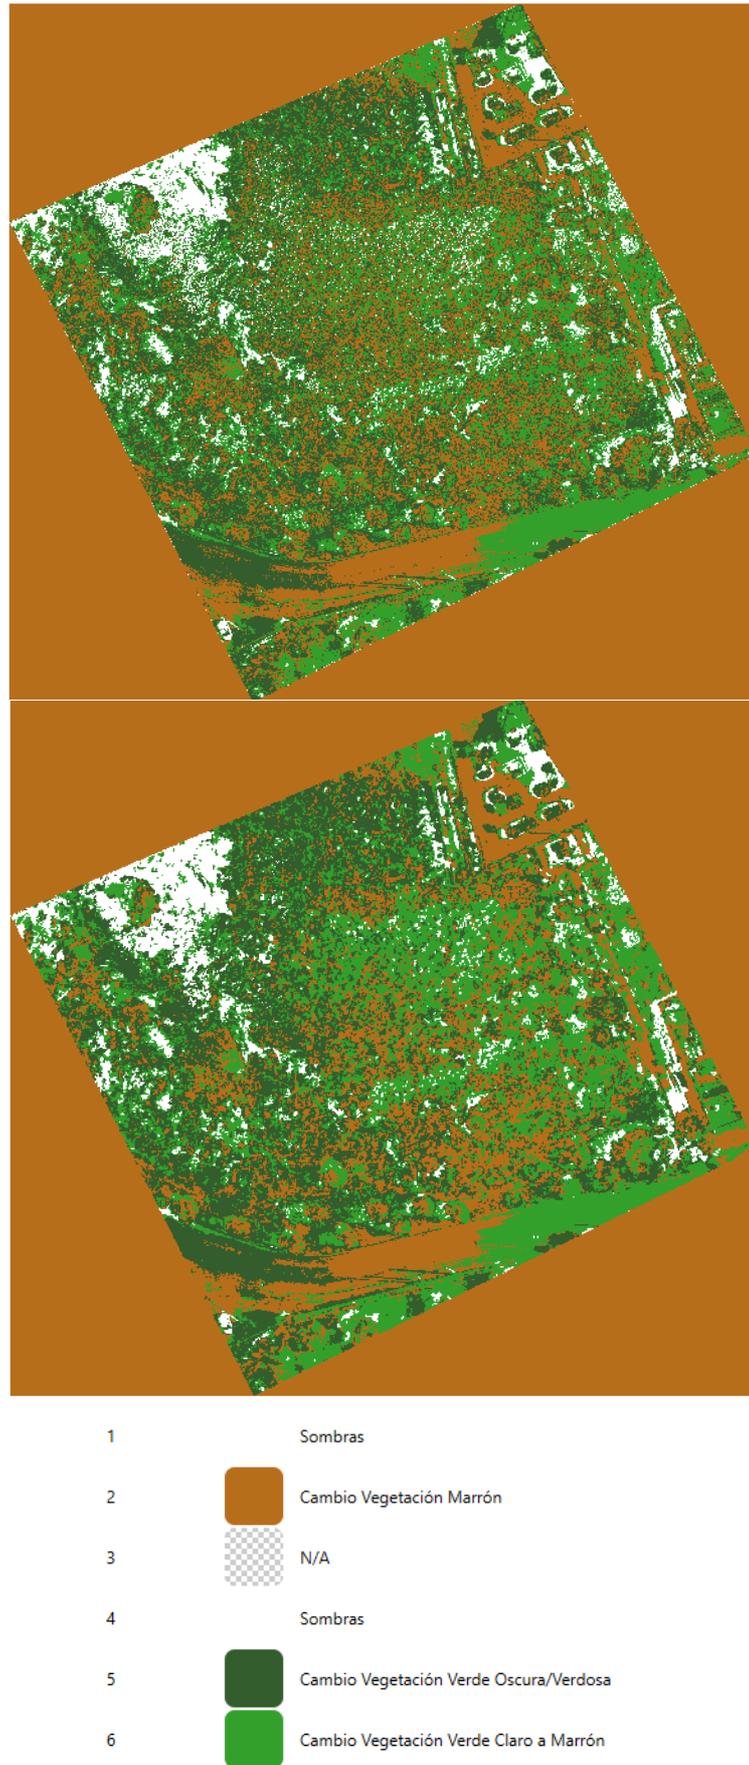


Figura 4-28: *Clustering* obtenido para la Zona 2, sin filtrar (arriba), filtrado (medio) y leyenda de colores (abajo).

Una vez se tienen los resultados presentados, se procede a realizar un análisis de los mismos. En la Figura 4-29, se puede observar un fragmento del *clustering* y de las ortofotos de 2017 y 2022 de la zona 1. En primer lugar, hay que destacar la clasificación en color blanco de las zonas de sombra fuerte, que se observan principalmente en la ortofotografía de 2017 proyectadas por los árboles. En color marrón, se observa cómo una franja de color grisáceo se extiende en la ortofoto de 2022, mientras que esa misma franja está cubierta por vegetación verdosa en 2017. Además, se clasifica en el mismo color marrón la parte cerca a los árboles que carece de vegetación en ambos años. Por último, en colores verde claro y oscuro, se observa como la vegetación baja de color más verdoso y el árbol que se encuentra en la esquina superior derecha en 2017, varían hasta convertirse en una zona árida y de colores marrones-amarillentos.

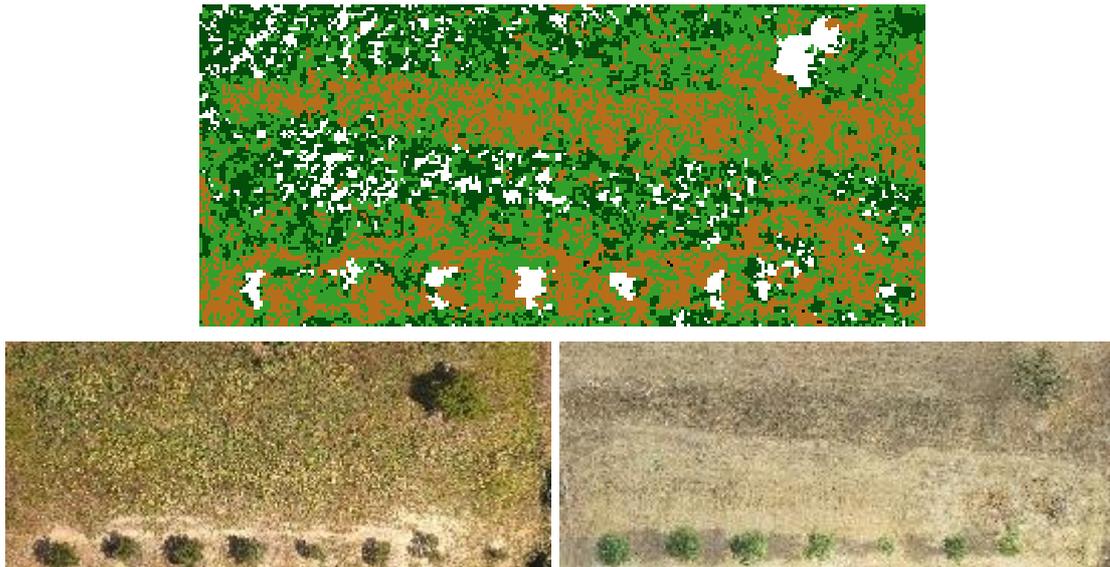


Figura 4-29: Zona 1. Fragmento de *clustering* (arriba), ortofoto 2017 (abajo izq.) y ortofoto 2022 (abajo dcha.).

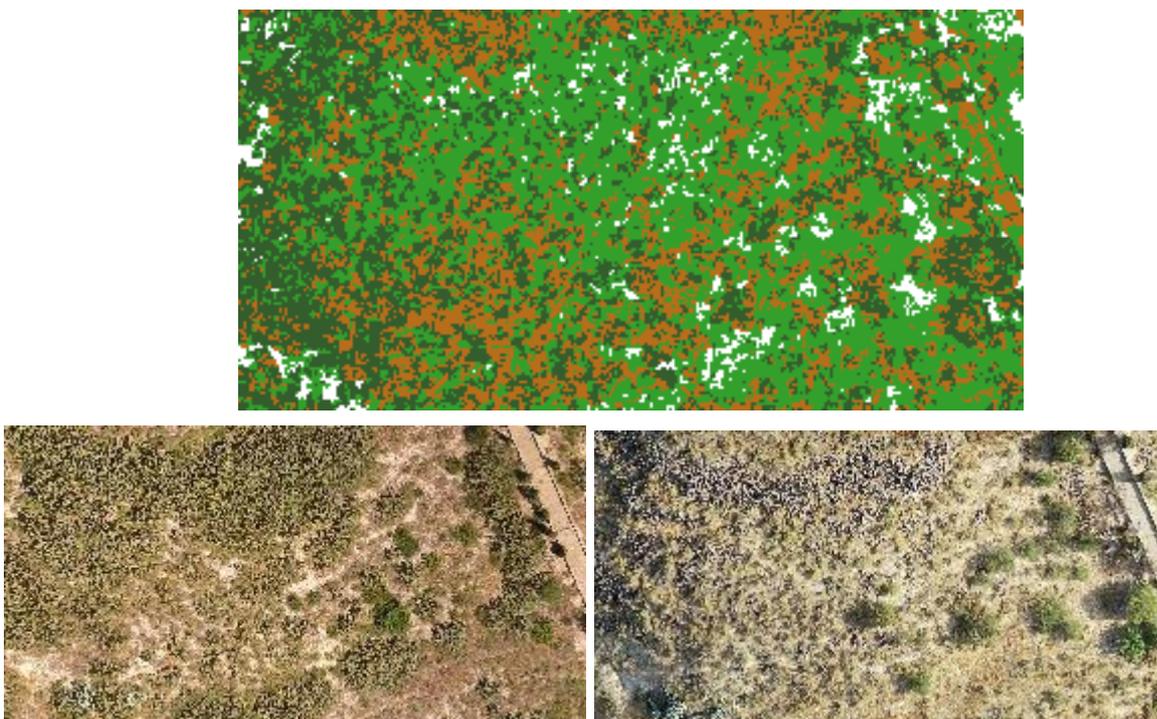


Figura 4-30: Zona 2. Fragmento de *clustering* (arriba), ortofoto 2017 (abajo izq.) y ortofoto 2022 (abajo dcha.).

Atendiendo a la Figura 4-30, se observa una zona de terreno donde se ha pasado de tener una vegetación verdosa en la parte superior en 2017 a que esa misma vegetación tenga colores marrones/grises en 2022. En el *clustering* realizado, esto se aprecia en color verde claro principalmente, que indica este paso a colores marrones. La otra clasificación que destaca es la de color marrón, que va ligada a zonas descubiertas de vegetación del terreno, que poseen color marrón al estar compuestas de tierra.

Para concluir este apartado, cabe destacar que el estudio realizado en el SCP, ha dado a luz la dificultad que tiene para realizar clasificaciones muy precisas, si bien sí que se puede extraer información sobre las variaciones en el terreno, es cierto que, para un número de bandas pequeño, como en nuestro caso, el modelo no es totalmente extrapolable, ya que requiere de una continua parametrización.



# 5 CONCLUSIONES

---

Para cerrar este Trabajo de Fin de Máster, se expondrán las principales conclusiones extraídas de su realización. Para comenzar, se abordarán las relacionadas con el levantamiento fotogramétrico llevado a cabo en Metashape®. Finalmente, se detallarán las relativas al estudio de la detección de cambios realizada mediante aprendizaje automatizado.

- Metashape® es un software de fácil instalación y uso, ya que presenta un flujo de trabajo con los pasos definidos que va guiando al usuario al no permitir avanzar en dicho flujo hasta que no se cumplen los pasos predecesores, lo que lo hace un programa muy intuitivo y útil para todo tipo de perfiles, aunque no tengan un nivel avanzado de fotogrametría. Además, existe gran diversidad de material didáctico sobre el software, al ser uno de los programas de fotogrametría más conocido a nivel mundial.
- La tarea más tediosa de realizar en Metashape® fue la verificación de los puntos de control. Si bien existe la posibilidad de importarlos mediante un archivo de texto y, automáticamente, se añaden a las fotografías cargadas, igualmente hay que ir a cada fotografía a verificar y posicionar en el lugar exacto el punto de control. En nuestro caso, al tener 567 fotografías y 71 puntos de control, se tuvieron que realizar más de 1500 verificaciones.
- La mayor ventaja de Metashape®, es la capacidad que ofrece para generar un modelo tridimensional de un objeto o terreno, y de sus productos derivados tales como la ortofoto, el modelo digital de elevaciones, etc., con una alta precisión y a un bajo coste económico. En el desarrollo de este proyecto, se ha obtenido el modelo tridimensional de una superficie de 40,000 m<sup>2</sup> utilizando únicamente un dron con cámara y un ordenador.
- La realización de un levantamiento fotogramétrico puede conllevar la necesidad de una gran capacidad de procesamiento gráfico. En este proyecto, durante la creación de la nube de puntos densa, se tuvo que hacer uso de un ordenador con mayor capacidad gráfica perteneciente a la Universidad de Sevilla para poder llevar a cabo su generación. Sin embargo, Metashape® ofrece un servicio de trabajo en la nube, para poder realizar procesamiento sin necesidad de tener un equipo tan caro.
- En cuanto al uso de QGIS® como Sistema de Información Geográfica (SIG), hay que destacar que se trata de un software libre y que se encuentra en continua actualización e implementación de mejoras. Además, posee una gran cantidad de complementos para instalar, como el utilizado en este proyecto, Semi-Automatic Classification Plugin (SCP).
- La integración de la consola Python dentro de la interfaz de QGIS® ofrece diversas posibilidades. Entre ellas destacan la automatización de procesos. En este proyecto, se ha llevado a cabo la codificación de varios *scripts* que permiten realizar operaciones con archivos ráster de forma automatizada, como operaciones aritméticas y aplicación de filtros de ruido, además de poder trabajar dentro de la misma secuencia de comandos con proyecciones en sistemas de referencia. Además, debido al auge de la inteligencia artificial (IA) aplicada a la programación, se puede obtener apoyo en lenguajes de codificación desconocidos para el usuario en la creación de *scripts*.
- La detección de cambios sobre la superficie de un objeto o terreno ligada a la variación de sus bandas RGB, es un buen punto de partida para la obtención de unas premisas iniciales que permitan,

posteriormente, obtener un resultado más preciso.

- Debido a la documentación realizada para la realización de este proyecto, se conoce que el complemento Semi-Automatic Classification Plugin es capaz de realizar clasificaciones muy precisas de diferentes tipos de superficies de un terreno, tanto en aprendizaje automatizado como semi-automatizado. Sin embargo, para que su funcionamiento sea preciso, se ha notado que necesita un gran número de bandas y de información dentro de ellas. En nuestro caso de estudio, al tener solamente 4 bandas, y, ser éstas obtenidas mediante la toma de fotografías aéreas por un dron y no, por ejemplo, desde un satélite tipo *Sentinel*, los resultados no han logrado ser completamente precisos, dando lugar a una clasificación de cambios que en algunos casos no coinciden con la realidad, por ejemplo, en las construcciones o carreteras. Aun así, se han conseguido identificar algunos patrones de variación relativa a la vegetación y la capa superficial del terreno.



# ANEXO A

## SECUENCIA DE COMANDOS (*SCRIPTS*) EN PYTHON

---

Se adjuntan las secuencias de comandos mencionadas en la Sección 3.3.

1. Obtención de ráster que contenga la diferencia entre las bandas verdes de dos ráster dato con posterior categorización según valor de la diferencia.
2. Obtención de apilamiento (*stack*) de las bandas pertenecientes a dos ráster con proyección en sistema EPSG25830.
3. Filtrado de ruido para ráster.

# 1. Obtención diferencia bandas verde entre 2 ráster dato.

```

from qgis.analysis import QgsRasterCalculator, QgsRasterCalculatorEntry
from qgis.core import QgsRasterLayer, QgsColorRampShader, QgsRasterShader,
QgsSingleBandPseudoColorRenderer, QgsProject
from qgis.PyQt.QtGui import QColor

# Rutas de las imágenes
imagen1_path = 'C:/Users/Usuario /Lebrija/Ortofoto_2017.tif' # Imagen más antigua
imagen2_path = 'C:/Users/Usuario /Lebrija/Ortofoto_2022.tif' # Imagen más reciente

# Cargar las imágenes como capas raster
imagen1 = QgsRasterLayer(imagen1_path, 'Imagen 1')
imagen2 = QgsRasterLayer(imagen2_path, 'Imagen 2')

if not imagen1.isValid() or not imagen2.isValid():
    print("Error al cargar las imágenes")
else:
    print("Imágenes cargadas correctamente")

### Cálculo de diferencias altimétricas ###
# Crear las entradas para el cálculo de diferencias RGB
entry1_green = QgsRasterCalculatorEntry()
entry2_green = QgsRasterCalculatorEntry()

# Asignar las bandas verdes (asociadas comúnmente a la vegetación o altitud)
entry1_green.ref = 'imagen1@2'
entry1_green.raster = imagen1
entry1_green.bandNumber = 2 # Banda verde

entry2_green.ref = 'imagen2@2'
entry2_green.raster = imagen2
entry2_green.bandNumber = 2 # Banda verde

entries_altimetria = [entry1_green, entry2_green]

# Fórmula para el cálculo de las diferencias altimétricas (usando la banda verde como aproximación)
formula_diferencia_altimetria = 'abs(imagen1@2 - imagen2@2)'

# Definir la ruta para el raster de salida de diferencias altimétricas
output_path_diferencias_altimetria = 'C:/Users/Usuario /Lebrija/Diferencias_banda_verde.tif'

```

```
# Ejecutar el cálculo para las diferencias altimétricas
```

```
raster_calculator_altimetria = QgsRasterCalculator(
    formula_diferencia_altimetrica,
    output_path_diferencias_altimetria,
    'GTiff', # Formato de salida
    imagen1.extent(),
    imagen1.width(),
    imagen1.height(),
    entries_altimetria
)
```

```
result_altimetria = raster_calculator_altimetria.processCalculation()
```

```
if result_altimetria == 0:
```

```
    print("Cálculo de diferencias altimétricas completado con éxito. La imagen de diferencias ha sido creada.")
```

```
else:
```

```
    print("Error en el cálculo de diferencias altimétricas.")
```

```
### Aplicar simbología de 5 escalas de verde para diferencias altimétricas ###
```

```
# Cargar la imagen de diferencias altimétricas generada
```

```
raster_diferencias = QgsRasterLayer(output_path_diferencias_altimetria, 'Diferencias Altimétricas')
```

```
if not raster_diferencias.isValid():
```

```
    print("Error al cargar la imagen de diferencias altimétricas.")
```

```
else:
```

```
    print("Imagen de diferencias altimétricas cargada correctamente.")
```

```
# Crear un color ramp shader para asignar colores
```

```
fcn_altimetria = QgsColorRampShader()
```

```
fcn_altimetria.setColorRampType(QgsColorRampShader.Interpolated)
```

```
# Definir las clases de diferencias altimétricas con una escala de 5 verdes (verde claro a oscuro)
```

```
clase1 = QgsColorRampShader.ColorRampItem(0, QColor(144, 238, 144), 'Diferencias bajas (Verde claro)')
```

```
clase2 = QgsColorRampShader.ColorRampItem(25, QColor(85, 170, 85), 'Diferencias medias-bajas')
```

```
clase3 = QgsColorRampShader.ColorRampItem(50, QColor(34, 139, 34), 'Diferencias medias (Verde intermedio)')
```

```
clase4 = QgsColorRampShader.ColorRampItem(75, QColor(0, 100, 0), 'Diferencias medias-altas')
clase5 = QgsColorRampShader.ColorRampItem(100, QColor(0, 70, 0), 'Diferencias altas (Verde oscuro)')

# Añadir las clases al shader
fcn_ altimetria.setColorRampItemList([clase1, clase2, clase3, clase4, clase5])

# Aplicar el shader al raster
shader_ altimetria = QgsRasterShader()
shader_ altimetria.setRasterShaderFunction(fcn_ altimetria)

# Asignar el shader al renderer
render_ altimetria = QgsSingleBandPseudoColorRenderer(raster_ diferencias.dataProvider(), 1,
shader_ altimetria)
raster_ diferencias.setRenderer(render_ altimetria)

# Añadir la capa con la simbología al mapa
QgsProject.instance().addMapLayer(raster_ diferencias)

print("Simbología aplicada con éxito. El raster clasificado está en el mapa.")
```

**#2. Obtención de *stack* de bandas pertenecientes a dos archivos ráster en EPSG:25830.**

```

import rasterio
import numpy as np
from rasterio.enums import Resampling

# Definir el CRS EPSG:25830
crs_epsg_25830 = 'EPSG:25830'

# Rutas a los archivos
ruta_rgb_1 = 'C:/Users/Usuario/Lebrija /Orto_Zona2_17_008.tif' # Ruta a la primera imagen RGB
ruta_dem_1 = 'C:/Users/Usuario/Lebrija /MDE_Zona2_17_008.tif' # Ruta al DEM de la primera imagen
ruta_rgb_2 = 'C:/Users/Usuario/Lebrija/Orto_Zona2_22_008.tif' # Ruta a la segunda imagen RGB
ruta_dem_2 = 'C:/Users/Usuario/Lebrija/MDE_Zona2_22_008.tif' # Ruta al DEM de la segunda imagen
ruta_stack_1 = 'C:/Users/Usuario/Lebrija/stack2017_Zona2.tif' # Ruta donde se guardará stack1
ruta_stack_2 = 'C:/Users/Usuario/Lebrija/stack2022_Zona2.tif' # Ruta donde se guardará stack2

# Cargar la primera imagen RGB
with rasterio.open(ruta_rgb_1) as src1:
    rgb1 = src1.read([1, 2, 3]) # Leer bandas RGB
    transform = src1.transform # Obtener la transformación
    crs = src1.crs # Obtener el sistema de referencia

# Reproyectar si es necesario
if crs.to_string() != crs_epsg_25830:
    print(f'Reproyectando la imagen RGB a {crs_epsg_25830}')
    rgb1, transform = rasterio.warp.reproject(
        source=rgb1,
        src_crs=crs,
        dst_crs=crs_epsg_25830,
        resampling=Resampling.nearest,
        dst_transform=transform
    )

# Cargar el DEM correspondiente a la primera imagen
with rasterio.open(ruta_dem_1) as dem1_src:
    dem1 = dem1_src.read(1) # Leer la banda DEM

# Reproyectar DEM si es necesario
if dem1_src.crs.to_string() != crs_epsg_25830:
    print(f'Reproyectando el DEM a {crs_epsg_25830}')

```

```

dem1, transform = rasterio.warp.reproject(
    source=dem1,
    src_crs=dem1_src.crs,
    dst_crs=crs_epsg_25830,
    resampling=Resampling.nearest,
    dst_transform=transform
)
# Expandir dimensiones del DEM para que coincidan
dem1_expanded = np.expand_dims(dem1, axis=0)
# Crear un stack de cuatro bandas (RGB + DEM) para la primera imagen
stack1 = np.concatenate([rgb1, dem1_expanded], axis=0)
# Guardar stack1 como archivo TIFF con el sistema EPSG:25830
with rasterio.open(ruta_stack_1, 'w', driver='GTiff', height=stack1.shape[1], width=stack1.shape[2],
    count=stack1.shape[0], dtype=stack1.dtype, crs=crs_epsg_25830, transform=transform) as dst1:
    dst1.write(stack1)
# Cargar la segunda imagen RGB
with rasterio.open(ruta_rgb_2) as src2:
    rgb2 = src2.read([1, 2, 3])
    transform = src2.transform
    crs = src2.crs
# Reproyectar si es necesario
if crs.to_string() != crs_epsg_25830:
    print(f'Reproyectando la imagen RGB a {crs_epsg_25830}')
    rgb2, transform = rasterio.warp.reproject(
        source=rgb2,
        src_crs=crs,
        dst_crs=crs_epsg_25830,
        resampling=Resampling.nearest,
        dst_transform=transform
    )
# Cargar el DEM correspondiente a la segunda imagen
with rasterio.open(ruta_dem_2) as dem2_src:
    dem2 = dem2_src.read(1)
# Reproyectar DEM si es necesario
if dem2_src.crs.to_string() != crs_epsg_25830:
    print(f'Reproyectando el DEM a {crs_epsg_25830}')
    dem2, transform = rasterio.warp.reproject(
        source=dem2,

```

```

src_crs=dem2_src.crs,
dst_crs=crs_epsg_25830,
resampling=Resampling.nearest,
dst_transform=transform
)
# Expandir dimensiones del DEM para que coincidan
dem2_expanded = np.expand_dims(dem2, axis=0)
# Crear un stack de cuatro bandas (RGB + DEM) para la segunda imagen
stack2 = np.concatenate([rgb2, dem2_expanded], axis=0)
# Guardar stack2 como archivo TIFF con el sistema EPSG:25830
with rasterio.open(ruta_stack_2, 'w', driver='GTiff', height=stack2.shape[1], width=stack2.shape[2],
count=stack2.shape[0], dtype=stack2.dtype, crs=crs_epsg_25830, transform=transform) as dst2:
    dst2.write(stack2)
# Comprobación
print(f'Shape de stack1: {stack1.shape}')
print(f'Shape de stack2: {stack2.shape}')

```

### # 3. Filtro de ruido mediante algoritmo media móvil.

```
from qgis.core import QgsRasterLayer
import processing

# Cargar la capa ráster de 1 banda (reemplaza 'ruta/a/tu_raster.tif' con la ruta de tu archivo)
ruta_raster = 'C:/Users/Usuario/Lebrija/Zona1_clusterizada.tif'
raster_layer = QgsRasterLayer(ruta_raster, 'Ráster de 1 banda')

if not raster_layer.isValid():
    print("La capa ráster no se pudo cargar.")
else:
    print("La capa ráster se cargó correctamente.")

# Crear el filtro de ruido utilizando la herramienta de "Filtro de media"
parametros = {
    'INPUT': raster_layer,
    'RADIUS': 2, # Radio del filtro. Influye en el radio de filtrado.
    'OUTPUT': 'TEMPORARY_OUTPUT'
}

resultado = processing.run("gdal:sieve", parametros)

# Guardar el resultado en un archivo de salida
ruta_salida = 'C:/Users/Usuario/Lebrija/Zona1_cluster_filtrada.tif'
parametros_guardado = {
    'INPUT': resultado['OUTPUT'],
    'OUTPUT': ruta_salida
}

processing.run("gdal:translate", parametros_guardado)

print(f'Filtro de ruido aplicado y guardado en: {ruta_salida}')
```



# REFERENCIAS

---

- [1] Interés por la Geomática (2014). El padre de la Fotogrametría Aimé Laussedat. Obtenido de: <https://interesporlageomatica.com/2014/02/25/el-padre-de-la-fotogrametria-aime-laussedat/> , Acceso: Octubre 2024.
- [2] Wikipedia (2024). Cámara lucida. Obtenido de: [https://es.wikipedia.org/wiki/Cámara\\_lúcida](https://es.wikipedia.org/wiki/Cámara_lúcida), Acceso: Octubre 2024.
- [3] L. Polidori, Université de Toulouse, France (2018). On Laussedat's contribution to the emergence of photogrammetry. Obtenido de: <https://isprs-archives.copernicus.org/articles/XLIII-B2-2020/893/2020/isprs-archives-XLIII-B2-2020-893-2020.pdf> , Acceso: Octubre 2024.
- [4] Página oficial de la ASPRS. Obtenido de: <https://www.asprs.org/>, Acceso: Octubre 2024.
- [5] Bitfab. Tipos de escaneados 3D. Obtenido de: <https://bitfab.io/es/blog/tipos-escaneado-3d/> , Acceso: Octubre 2024.
- [6] PAR Patrimonio (2014). Segóbriga y la fotogrametría para la reconstrucción 3D. Obtenido de: <https://parpatrimonioytecnologia.wordpress.com/2014/01/20/segobriga-la-fotogrametria-como-base-para-la-reconstruccion-3d/> , Acceso: Octubre 2024.
- [7] Drone By Drone (2021). Modelo 3D Volcán La Palma junto a CSIC. Obtenido de: <https://www.dronebydrone.com/noticias/635/modelo-digital-en-3d-de-coladas-del-volcan-de-cumbre-vieja-en-la-palma-mediante-drones-uas.html> , Acceso: Octubre 2024.
- [8] Página oficial de la OACI. Obtenido de: <https://www.icao.int/> , Acceso: Octubre 2024.
- [9] Instituto Geográfico Nacional. Obtenido de: <https://www.transportes.gob.es/instituto-geografico-nacional> , Acceso: Octubre 2024.
- [10] Página oficial del PNOA. Obtenido de: <https://pnoa.ign.es/web/portal/pnoa-imagen/vuelo-fotogrametrico> , Acceso: Octubre 2024.
- [11] Visualizador IGN PNOA. Obtenido de: [https://visualizadores.ign.es/comparador\\_pnoa/](https://visualizadores.ign.es/comparador_pnoa/) , Acceso: Octubre 2024.
- [12] Woolpert. Manned vs Unmanned Aircraft. Obtenido de: <https://woolpert.com/news/blogs/manned-vs-unmanned-aircraft-which-is-best-for-aerial-data-acquisition/> , Acceso: Octubre 2024.
- [13] Instituto Geográfico Nacional. Teledetección. Obtenido de: <https://www.ign.es/web/resources/docs/IGNCnig/OBS-Teledeteccion.pdf> , Acceso: Octubre 2024.
- [14] NASA Appliedsciences. Fundamentos de la Teledetección. Obtenido de: [https://appliedsciences.nasa.gov/sites/default/files/2023-02/Fundamentals\\_of\\_RS\\_Span.pdf](https://appliedsciences.nasa.gov/sites/default/files/2023-02/Fundamentals_of_RS_Span.pdf), Acceso: Octubre 2024.
- [15] EOS Data Analytics (2021). Teledetección Satelital. Obtenido de: <https://eos.com/es/blog/teledeteccion/> , Acceso: Octubre 2024.
- [16] Geoinnova (2017). Aplicaciones de la Teledetección Ambiental. Obtenido de: <https://geoinnova.org/blog-territorio/aplicaciones-de-la-teledeteccion-ambiental/> , Acceso: Octubre 2024.
- [17] GIS&Beers (2019). Técnicas de análisis de masas de agua con teledetección. Obtenido de: <https://www.gisandbeers.com/tecnicas-analisis-masas-de-agua-teledeteccion/> , Acceso: Octubre 2024.
- [18] Graniot (2021). Teledetección aplicada a la agricultura. Obtenido de: <https://graniot.com/blog/teledeteccion-un-gran-aliado-en-la-agricultura-de-precision/> , Acceso: Octubre 2024.

## Referencias

- [19] Microsiervos (2015). Primeras imágenes Sentinel-2A. Obtenido de: <https://www.microsiervos.com/archivo/ciencia/satelite-mediaambiental-sentinel-2a-capta-primeras-imagenes.html> , Acceso : octubre 2024.
- [20] Instituto Geográfico Nacional. Proyecto PNOA LiDAR. Obtenido de: <https://pnoa.ign.es/web/portal/pnoa-lidar/presentacion> , Acceso: Octubre 2024.
- [21] Gobierno de España, datos.gob (2020). Machine Learning y sus diferentes tipos. Obtenido de: <https://datos.gob.es/es/blog/como-aprenden-las-maquinas-machine-learning-y-sus-diferentes-tipos> , Acceso: 2024.
- [22] IBM. ¿Qué es el Machine Learning? Obtenido de: <https://www.ibm.com/es-es/topics/machine-learning> , Acceso: 2024.
- [23] Ejable (2023). Random Forest in ML Obtenido de: <https://www.ejable.com/tech-corner/ai-machine-learning-and-deep-learning/random-forest-in-machine-learning/> , Acceso: Octubre 2024.
- [24] UNITECO (2023). ML en la medicina. Obtenido de: <https://www.unitecoprofesional.es/blog/machine-learning-medicina-futuro-profesion/> , Acceso: Octubre 2024.
- [25] Universidad de Chile (2024). Uso de drones e IA para medir estado de pavimentos. Obtenido de: <https://www.ing.uc.cl/noticias/ingenieros-chilenos-prueban-ia-y-drones-para-medir-estado-de-pavimentos/> , Acceso: Octubre 2024.
- [26] UAVLatam (2022). ¿Qué es y para qué sirve la fotogrametría? Obtenido de: <https://uavlatam.com/que-es-la-fotogrametria-como-funciona/> , Acceso: Octubre 2024.
- [27] B. Toharias, Universidad de Sevilla, España (2020). Comparativa entre software propietario y libre en levantamientos fotogramétricos con RPAs. Obtenido de: <https://idus.us.es>.
- [28] Zonas de estudio alrededor del Castillo-Fortaleza de Lebrija. Obtenido de: <https://maps.google.com> , Acceso: Octubre 2024.
- [29] Weatherspark, (2024). Clima y tiempo promedio en todo el año en Lebrija. Obtenido de: <https://es.weatherspark.com/y/33180/Clima-promedio-en-Lebrija-España-durante-todo-el-año> , Acceso: Octubre 2024.
- [30] Andalucía Ecológica (2022). La reconversión de los floricultores de las marismas de Lebrija. Obtenido de: <https://andaluciaecologica.com/la-reconversion-de-los-floricultores-de-las-marismas-de-lebrija/> , Acceso: Octubre 2024.
- [31] DJI (2016). Phantom 4 support. Obtenido de: <https://www.dji.com/es/support/product/phantom-4> , Acceso: Octubre 2024.
- [32] Skyop. Phantom 4 flying. Obtenido de: <https://www.skyop.com/courses/hands-on-drone-flight-training-dji-phantom-4-series/> , Acceso: Octubre 2024.
- [33] DJI. Phantom 4 User Manual (2016). Obtenido de: [https://dl.djicdn.com/downloads/phantom\\_4/en/Phantom\\_4\\_User\\_Manual\\_en\\_v1.2\\_20160805.pdf](https://dl.djicdn.com/downloads/phantom_4/en/Phantom_4_User_Manual_en_v1.2_20160805.pdf) , Acceso: Octubre 2024.
- [34] Surveydrones. Grid sample in Pix4DCapture. Obtenido de: <https://surveydrones.ie/pix4dsoftware/pix4d-capture-2/> , Acceso: Octubre 2024.
- [35] Medium (2019). Solape en Fotogrametría. Obtenido de: <https://medium.com/@coatzadroneoficial/para-que-sirve-el-traslape-en-fotogrametría-con-rpas-2949b2ddf21b> , Acceso: Octubre 2024.
- [36] Heliguy. GSD Calculator. Obtenido de: <https://www.heliguy.com/gsdCalculator/> , Acceso: Octubre 2024.
- [37] Wikipedia (2017). Phantom 4 Pro flying. Obtenido de: [https://es.wikipedia.org/wiki/Archivo:DJI\\_Phantom\\_4Pro\\_04-2017\\_img3\\_in\\_flight.jpg](https://es.wikipedia.org/wiki/Archivo:DJI_Phantom_4Pro_04-2017_img3_in_flight.jpg) , Acceso: Octubre 2024.
- [38] DJI (2021). Phantom 4 Pro Specifications. Obtenido de: <https://www.dji.com/es/support/product/phantom-4-pro> , Acceso: Octubre 2024.
- [39] DJI (2021). Phantom 4 Pro User Manual. Obtenido de: [https://dl.djicdn.com/downloads/phantom\\_4\\_pro/20211129/UM/Phantom\\_4\\_Pro\\_Pro\\_Plus\\_Series\\_User\\_Man](https://dl.djicdn.com/downloads/phantom_4_pro/20211129/UM/Phantom_4_Pro_Pro_Plus_Series_User_Man)

ual\_ES.pdf , Acceso: Octubre 2024.

[40] Agisoft Metashape (2024). Manual de usuario. Obtenido de: [https://www.agisoft.com/pdf/metashape\\_2\\_1\\_en.pdf](https://www.agisoft.com/pdf/metashape_2_1_en.pdf) , Acceso: 2024.

[41] Panacea Cooperative Research. Manual Agisoft Metashape. Obtenido de: <https://skeleton-id.com/wp-content/uploads/2021/01/Manual-Agisoft-Metashape.pdf> , Acceso: Octubre 2024.

[42] Qiusheng Wu (2024). Rasterio Library. Obtenido de: <https://geog-312.gishub.org/book/geospatial/rasterio.html> , Acceso: 2024.

[43] Luca Congedo (2017) Semi-Automatic Classification Plugin Manual. Obtenido de: <https://semiautomaticclassificationmanual-v5.readthedocs.io/> , Acceso: Octubre 2024.

[44] Página oficial de Numpy®. Obtenido de: <https://numpy.org> , Acceso: Octubre 2024.