



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Técnica Superior de Ingeniería Geodésica,
Cartográfica y Topográfica

Tratamiento de las imágenes Sentinel 2 para su uso en el
cálculo de aerosoles en la ciudad de Valencia.

Trabajo Fin de Grado

Grado en Ingeniería Geomática y Topografía

AUTOR/A: Portales Girona, Adrian

Tutor/a: Coll Aliaga, Peregrina Eloína

Cotutor/a: Porres de la Haza, Maria Joaquina

Director/a Experimental: LORENZO SAEZ, EDGAR

CURSO ACADÉMICO: 2021/2022

AGRADECIMIENTOS

Por la realización de este proyecto debo agradecer a Edgar Lorenzo Sáez y Eloina Coll Aliaga por ofrecerme la oportunidad de participar en un proyecto tan importante e interesante como es el proyecto de airLUISA. Además, en este proyecto he tenido la oportunidad de colaborar en grupo con personas muy capacitadas como son, Javier Sola Ferrer por apoyar con sus conocimientos avanzados del Máster en Ingeniería Geomática y Geoinformación, a Adrián Simarro González por colaborar tanto entre nosotros durante el trabajo y por último a María Joaquina Porres de la Haza por guiarnos tan bien y ayudarnos tanto para que fuéramos capaces de entender y realizar todos los objetivos del trabajo.

COMPROMISO

"El presente documento ha sido realizado completamente por el firmante; no ha sido entregado como otro trabajo académico previo y todo el material tomado de otras fuentes ha sido convenientemente entrecomillado y citado su origen en el texto, así como referenciado en la bibliografía"

RESUMEN

Este proyecto forma parte de un trabajo de investigación cuyo objetivo es definir una metodología capaz de medir niveles de contaminantes como el NO_2 y el $\text{PM}_{2.5}$ en la ciudad de València, mediante imágenes de satélite. A través de la determinación de la cantidad de aerosoles (AOD, Aerial Optical Depth) en la atmósfera es posible definir la contaminación. Sin embargo, el reto del trabajo en el que está incluido este proyecto, es definir los valores de AOD a partir de imágenes de satélite de alta resolución espacial. Las imágenes empleadas provienen del satélite Sentinel-2 y los valores de contaminantes se obtienen de diferentes campañas de dosimetría en la ciudad de València.

Dentro de la metodología definida en el trabajo de investigación, una parte importante radica en la detección de las zonas con nubes donde la medición del AOD no es posible. Además de determinación de las zonas no cambiantes del área de estudio que permitirán el cálculo de la reflectancia en superficie necesaria para la determinación del AOD. Este proyecto se centra en la obtención de estos dos parámetros.

El trabajo en el que se engloba este proyecto tiene una gran utilidad social, permite tener un gran control de los gases contaminantes en las ciudades de forma rápida y sin costosas campañas que solo muestran datos puntuales y no en toda la ciudad. Hasta ahora ya se han hecho trabajos similares a este, sin embargo se diferencia por el uso de una cantidad de imágenes mucho mayor y por el uso de los datos que provienen de un número elevado de estaciones en tierra.

Aquest projecte forma part d'un treball de recerca que té com a objectiu definir una metodologia capaç de mesurar nivells de contaminants com el NO₂ i el PM_{2.5} a la ciutat de València, mitjançant imatges de satèl·lit. A través de la determinació de la quantitat d'aerosols (AOD, Aerial Optical Depth) a l'atmosfera és possible definir la contaminació. Tot i això, el repte del treball en què està inclòs aquest projecte és definir els valors d'AOD a partir d'imatges de satèl·lit d'alta resolució espacial. Les imatges emprades provenen del satèl·lit Sentinel-2 i els valors de contaminants s'obtenen de diferents campanyes de dosimetria a la ciutat de València.

Dins la metodologia definida al treball de recerca, una part important rau en la detecció de les zones amb núvols on el mesurament de l'AOD no és possible. A més de determinació de les zones no canviants de l'àrea estudiada que permetran el càlcul de la reflectància en superfície necessària per a la determinació de l'AOD. Aquest projecte se centra en obtenir aquests dos paràmetres.

El treball en què s'engloba aquest projecte té una gran utilitat social, permet tenir un gran control dels gasos contaminants a les ciutats de forma ràpida i sense costoses campanyes que només mostren dades puntuals i no a tota la ciutat. Fins ara ja s'han fet treballs similars a aquest, però es diferencia per l'ús d'una quantitat d'imatges molt més gran i per l'ús de les dades que provenen d'un nombre elevat d'estacions a terra.

This project is part of a research project whose objective is to define a methodology capable of measuring levels of pollutants such as NO₂ and PM_{2.5} in the city of Valencia, using satellite images. Through the determination of the amount of aerosols (AOD, Aerial Optical Depth) in the atmosphere it is possible to define pollution. However, the challenge of the work in which this project is included is to define the AOD values from high spatial resolution satellite images. The images used come from the Sentinel-2 satellite and the pollutant values are obtained from different dosimetry campaigns in the city of Valencia.

Within the methodology defined in the research work, an important part lies in the detection of areas with clouds where the measurement of AOD is not possible. In addition to the determination of the non-changing zones of the study area that will allow the calculation of the surface reflectance necessary for the determination of the AOD. This project focuses on obtaining these two parameters.

The work in which this project is included has a great social utility, it allows to have a great control of the polluting gases in the cities quickly and without costly campaigns that only show punctual data and not in the whole city. Until now, similar works to this have already been done, however it differs by the use of a much larger number of images and by the use of data that comes from a large number of ground stations.

ÍNDICE DE ILUSTRACIONES

Ilustración 1. Composición de la atmósfera, fuente: "Cuadrat y Pita"	9
Ilustración 2. Mapa de la zona de estudio, fuente: elaboración propia	12
Ilustración 3. Organigrama del trabajo de investigación, fuente: elaboración propia	18
Ilustración 4. Ejemplo máscara de nubes Sen2cor, fuente: elaboración propia	20
Ilustración 5. Ejemplo de enmascaramiento mediante S2cloudless, fuente: elaboración propia	21
Ilustración 6. Parámetros usados en S2cloudless, fuente: elaboración	22
Ilustración 7. Máscara con probabilidad del 10%, fuente: elaboración propia	22
Ilustración 8. Máscara con probabilidad del 50%, fuente: elaboración propia	23
Ilustración 9. Máscara con probabilidad del 30%, fuente: elaboración propia	23
Ilustración 10. Vector cambio, fuente: elaboración propia	24
Ilustración 11. Respuesta espectral de diferentes tipos de suelo, fuente: "https://gidahatari.com/ih-es/tutorial-dedeterminación-de-huellas-espectrales-de- cobertura-de-suelos-con-qgis-3-y-scp-6"	25
Ilustración 12. Distribución normal de las clases, fuente: elaboración propia	27
Ilustración 13. Ejemplo1 del tono de cambio magenta, fuente elaboración propia.....	28
Ilustración 14. Ejemplo 2 del tono de cambio magenta, fuente: elaboración propia.....	29
Ilustración 15. Ejemplo 1 del tono de cambio azul, fuente: elaboración propia	29
Ilustración 16. Ejemplo 2 del tono de cambio azul, fuente: elaboración propia	30
Ilustración 17. Ejemplo 1 del tono de cambio amarillo, fuente: elaboración propia	30
Ilustración 18. Ejemplo 2 del tono de cambio amarillo, fuente: elaboración propia	31
Ilustración 19. Ejemplo del tono de cambio verde, fuente: elaboración propia.....	31
Ilustración 20. Ejemplo 2 del tono de cambio verde, fuente: elaboración propia.....	32
Ilustración 21. Mapa de máscara de zonas invariantes, fuente: elaboración propia	32
Ilustración 22. Mapa de zonas invariantes superpuesto con las zonas de cambio, fuente: elaboración propia	33
Ilustración 23. Salarios convenio de ingenieros y oficina técnica, fuente: BOE-A-2019-14977	34

ÍNDICE DE TABLAS

Tabla 1. Satélites usado para el monitoreo de contaminantes, fuente: artículo citado [1]	10
Tabla 2. Satélites estudiados para el proyecto, fuente: elaboración propia.....	13
Tabla 3. Filtrado de imágenes de 2018, fuente: elaboración propia	14
Tabla 4. Filtrado de imágenes de 2019, fuente: elaboración propia	15
Tabla 5. Filtrado de imágenes de 2020, fuente: elaboración propia	16
Tabla 6. Filtrado de imágenes de 2021, fuente: elaboración propia	17
Tabla 7. Estadísticas de las clases, fuente: elaboración propia	26
Tabla 8. Remuneración de los trabajadores por el convenio de ingenieros y oficina técnica, fuente: elaboración propia.....	34
Tabla 9. Costes de los trabajadores por el convenio de ingenieros y oficina técnica, fuente: elaboración propia	34
Tabla 10. Coste del material utilizado, fuente: elaboración propia	34
Tabla 11. Costes por actividad y totales del proyecto, fuente: elaboración propia	35

ÍNDICE DE ECUACIONES

Ecuación 1: Incremento de reflectancia en la banda 4	25
Ecuación 2: Incremento de reflectancia en la banda 8	25
Ecuación 3: Módulo de un vector	25
Ecuación 4: Cálculo de un ángulo a partir de incrementos	25
Ecuación 5: Ecuación x de cambio de espacio de color HSI a RGB.....	26
Ecuación 6: Ecuación y de cambio de espacio de color HSI a RGB.....	26
Ecuación 5: Ecuación z de cambio de espacio de color HSI a RGB.....	26

ÍNDICE

AGRADECIMIENTOS.....	1
COMPROMISO	2
RESUMEN	3
1. INTRODUCCIÓN	9
2. OBJETIVO	11
3. ZONA DE ESTUDIO	12
4. DATOS	13
4.1. Imágenes satelitales	13
5. METODOLOGÍA.....	18
5.1. Enmascaramiento de nubes.....	20
5.2. Detección de zonas invariantes	24
6. RESULTADOS.....	28
7. PRESUPUESTO.....	34
8. CONCLUSIONES.....	36
9. BIBLIOGRAFÍA	37
10. ANEXOS	38
11. CARTOGRAFÍA.....	38

1. INTRODUCCIÓN

Hoy en día, alrededor del 55% de la población mundial viven en ciudades y se tiene previsto que aumente hasta el 68% en el 2050. Como consecuencia una alta densidad de población realiza sus actividades diarias en espacios relativamente reducidos lo que puede disminuir la calidad del aire siendo perjudicial para la salud. En la Unión Europea (EU) más de 400.000 personas mueren como consecuencia de la contaminación aérea [1] y alrededor de 6.5 millones de personas sufren alguna enfermedad causada por la misma [2]. Estos contaminantes derivan del gran flujo de vehículos además de las propias industrias de la ciudad como la zona portuaria la cual es un punto de gran afluencia de camiones de carga y barcos que expulsan gases contaminantes a la atmósfera de la ciudad, lo que provoca concentraciones dañinas para las personas.

En este proyecto se quería estudiar los contaminantes en la ciudad de València. En primer lugar, sería recomendable conocer la composición de gases en la atmosfera, la cual en un 99,95% se compone de nitrógeno, oxígeno y argón, el resto de la composición está formada por una variedad de gases con un diminuto volumen tal y como se observa en la ilustración 1.

COMPONENTES	FÓRMULA QUÍMICA	VOLUMEN% (AIRE SECO)
Nitrógeno	N ₂	78.08
Oxígeno	O ₂	20.95
Argón	Arkansas	0.93
dioxido de carbono	CO ₂	350 ppmv
Neón	No.	18,2 ppmv
Helio	Oye	5,24 ppmv
Metano	Canal ₄	2 ppmv
Criptón	kr	1,1 ppmv
Hidrógeno	H ₂	0,5 ppmv
Óxido nitroso	N ₂ O	0,3 ppmv
Xenón	Xe	0,08 ppmv
Monóxido de carbono	CO	0,05 - 0,2 ppmv
Ozono	O ₃	0,02 - 0,03 ppmv

Ilustración 1. Composición de la atmósfera, fuente: "Cuadrat y Pita"

Más en concreto en este proyecto se trabaja con el NO₂ y el PM_{2.5} dado que son los contaminantes más abundantes en las ciudades europeas [3] y por sus consecuencias para la salud de los ciudadanos. Con el fin de obtener los valores de concentración de los contaminantes anteriores, se quiere definir los aerosoles en la atmosfera debido a que estos representan las partículas en suspensión en la columna de aire. El AOD se define como la medición de la dispersión y absorción de luz visible por las partículas presentes en la columna vertical de aire, la lectura de los valores de AOD ayuda a determinar la calidad del aire porque es un valor proporcional a la concentración de partículas atmosféricas y por ende los contaminantes presentes.

Históricamente tal como muestra el estudio anteriormente mencionado se han utilizado diversos satélites y sensores para el estudio de gases en la atmósfera con características diferentes entre sí, en la tabla 1 se muestran unos de los principales usados o en activo actualmente, con sus características y los productos que ofrecen.

Sensor	Satélite	Resolución Espacial	Resolución Temporal	Productos
GOME-1	ERS-2	320x40 km	3 días	NO ₂ , SO ₂ , AOT and O ₃
MODIS	Terra	0,25-1 km	1-2 días	AOT
MISR	Terra	0,275 km	9 días	AOT
MOPITT	Terra	22x22 km	3 días	CO and NH ₄
SCIMACHY	ENVISAT	30x60 km	6 días	NO ₂ and SO ₂
OMI	Aura	13x24 km	1 día	O ₃ , SO ₂ , HCHO and NO ₂
TES	Aura	5x8 km	2 días	O ₃ , CO, CO ₂ and NH ₃
GOME-2	MetOP	40x80 km	1,5 días	NO ₂ , SO ₂ , AOT and O ₃
IASI	MetOP	50x50 km	0,5 días	SO ₂ , CO, NH ₃ , NH ₄ and CO ₂
TROPOMI	Sentinel-5P	3,5x7 km	1 día	O ₃ , NO ₂ , SO ₂ , CO, NH ₄ and formaldehyde

Tabla 1. Satélites usados para el monitoreo de contaminantes, fuente: artículo citado [1]

Sobre este tema de investigación se han realizado varios proyectos similares. Un artículo ambientado en la ciudad de Múnich, Alemania [5] en el cual se compararon diferentes algoritmos para la obtención de AOD de imágenes Sentinel-2 evaluando con dos estaciones de AERONET que hacen mediciones en tierra de los valores de AOD, además con los valores de AOD de las imágenes se realiza una correlación lineal con valores de PM_{2.5}. Otro artículo ambientado en la ciudad de Beijing, China [6] en el cual se calculó los valores de AOD a partir de imágenes Landsat-8 y Sentinel-2 que se compararon en este caso con tres estaciones de AERONET para evaluar los valores obtenidos por satélite con diferentes algoritmos, estudiando la variabilidad espacial del AOD.

En comparación con los artículos anteriores en el trabajo de investigación en el que se engloba este proyecto se van a utilizar los valores de AOD obtenidos de imágenes de Sentinel-2 para definir una correlación tanto con valores de PM_{2.5} como de NO₂ y estudiar su variabilidad espacial y temporal en la ciudad de València desde el año 2018 hasta 2021.

Respecto a la parte de tratamiento de imágenes que se realiza en este proyecto cabe destacar que en la actualidad es un campo muy estudiado donde se han realizado una gran cantidad de trabajos, aunque no tantos con este fin. Aun así, este proyecto es una de las partes más importantes del trabajo dado que un mal tratamiento de las imágenes o una falta de rigurosidad en el proceso desembocará en un resultado incongruente o lo que sería peor un resultado que no muestre la realidad física que se estudia sin crear errores groseros fácilmente reconocibles que podrían ser eliminados.

2. OBJETIVO

Como ya se explicó en apartado de introducción, este proyecto forma parte de un trabajo de investigación que en colaboración con la Cátedra de Governança de la ciutat de València tiene como objetivo determinar el nivel de contaminación en la ciudad de València. Este proyecto cubre algunos procedimientos necesarios para su consecución. Las tareas a realizar, que configuran a la vez los objetivos principales de mi proyecto, son:

1. Realizar la descarga masiva de las imágenes de satélite empleadas en el estudio.
2. Definir zonas cubiertas por nubes con el fin de eliminarlas del estudio general.
3. Determinar áreas sin cambios temporales.

Por otra parte, supone un reto transversal desarrollar la capacidad de trabajar en un grupo formado por profesores y varios alumnos de máster y de otros grados.

Por último, el objetivo final de este proyecto es demostrar mediante la realización de este trabajo, que he adquirido las competencias requeridas para la obtención del título de Grado en Geomática y Topografía, tal y como establece la normativa.

3. ZONA DE ESTUDIO

El proyecto se desarrolla en la ciudad de València, capital de provincia en la Comunidad Valenciana en España. La localidad está presente en las coordenadas geográficas (-0.6820,39.2608 : -0.2311,39.6253) usando el sistema de referencia WGS 84, en la costa con el mar mediterráneo. Las imágenes satelitales cubren una gran superficie de terreno por lo que se ha reducido el estudio al recorte que se puede observar en el mapa que se encuentra en el apartado de cartografía o en la ilustración 2. En el recorte elegido para el proyecto la zona está conformada tanto por zonas urbanas, como zonas de cultivo y zonas de vegetación natural. Además, en la ciudad de València y alrededores se situaron diferentes estaciones de dosimetría para medir los niveles de concentración de NO₂ en suelo con los que correlacionar los valores de AOD y NO₂.

La ciudad tiene una elevación casi nula respecto al nivel del mar debido a su cercanía con la costa, con una población aproximada de 789744 habitantes en 2021 según los datos que ofrece el INE (Instituto Nacional de Estadística). Por último, hay que añadir que en el área de la ciudad de València existe un gran tráfico de vehículos, también existe una industria contaminante, además de tener una zona portuaria que tiene una gran influencia en la calidad del aire de las zonas circundantes debido a la gran importancia del puerto de la ciudad en el mediterráneo.

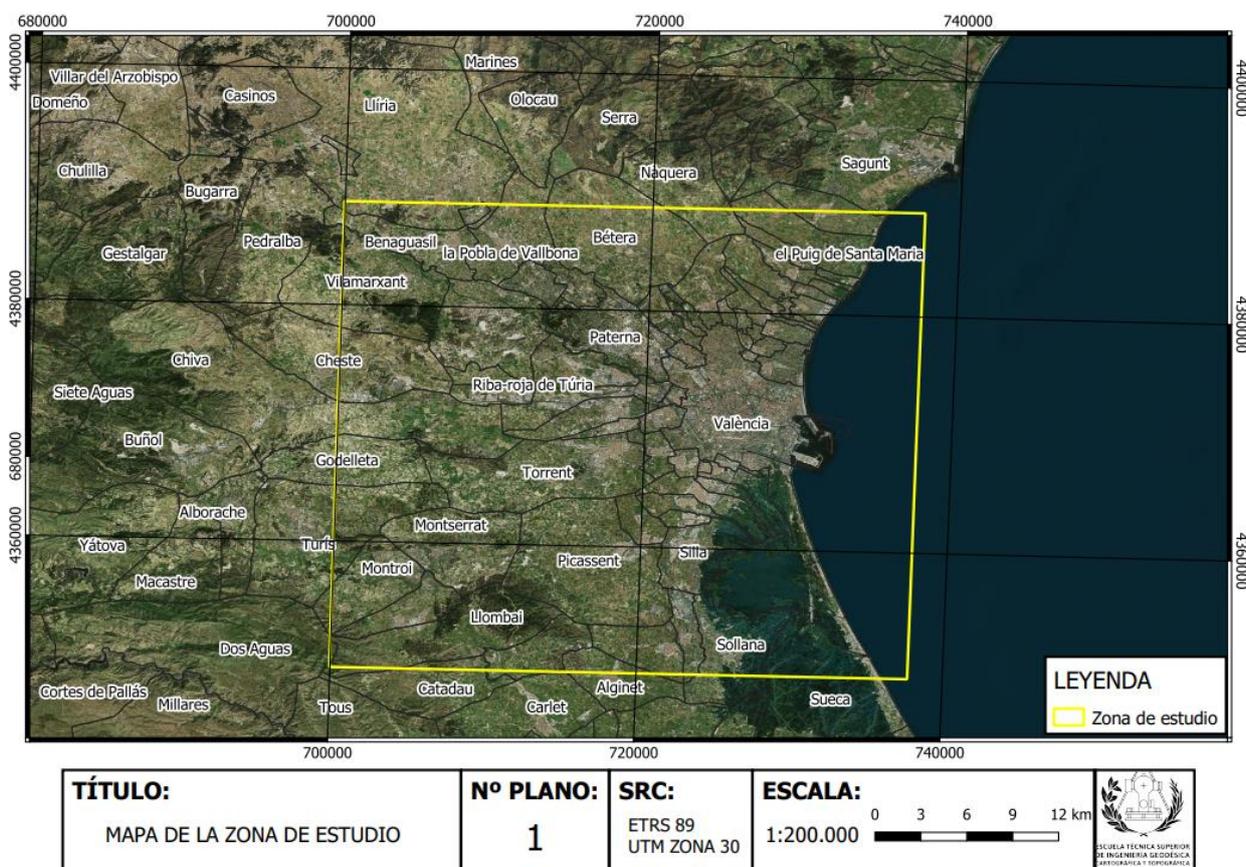


Ilustración 2. Mapa de la zona de estudio, fuente: elaboración propia

4. DATOS

4.1. Imágenes satelitales

En el trabajo se pretende utilizar imágenes satelitales, sin embargo dichas imágenes pueden tener características muy dispares dependiendo del satélite y sensor del cual provengan tal como se ha mostrado en la tabla 1 anteriormente. Por lo que el primer paso es estudiar qué características necesitan tener las imágenes para que cumplan con las necesidades del proyecto. La finalidad del trabajo es estudiar la ciudad de València, una zona de estudio con una gran variabilidad espacial y un área muy reducida, además se pretende estudiar la concentración de los contaminantes y su variación en el tiempo.

Estas necesidades obligan a buscar un satélite que ofrezca imágenes con una alta resolución espacial, para poder observar la variabilidad espacial de las concentraciones de contaminantes y que se puedan obtener imágenes con una resolución temporal reducida, para estudiar su variación en el tiempo. Tras observar diversas opciones se ha reducido la elección a las opciones que se muestran en la tabla 2.

Satélite	Res. Espacial	Res. Temporal	Algún producto atmosférico
Sentinel 5P	7x3.5 km	1 día	Si
Sentinel 2	10, 20, 60 m	5 días	No
Landsat 8	30, 100 m	16 días	No
Terra	0,25-1 km	1-2 días	Si

Tabla 2. Satélites estudiados para el proyecto, fuente: elaboración propia

Con todas las posibilidades que se han estudiado la opción elegida es el uso de Sentinel-2, este sistema de satélites está conformado de dos satélites, Sentinel-2A y Sentinel-2B, de esta forma se obtiene su resolución temporal de 5 días. Se ha elegido esta opción por su alta resolución espacial y su buena resolución temporal, a pesar de no tener un producto directo de NO₂, AOD o PM2.5. Por lo tanto, en este proyecto se determinará una metodología para poder obtener los valores de AOD y a partir de estos los valores de los contaminantes.

Teniendo en cuenta lo anterior se han obtenido imágenes de los meses en los que se realizaron campañas de dosimetría (febrero, mayo, agosto, noviembre) desde el año 2018 hasta el año 2021. Se han descargado imágenes de dos niveles de procesamiento diferente (1C y 2A) que ofrece Sentinel-2 debido a que será necesario en el proyecto tal y como se muestra en el apartado de metodología. Una imagen de nivel 1C es aquella que tiene presentes en sus valores la influencia de los elementos de la atmósfera, mientras que el nivel 2A se obtiene tras corregir este efecto atmosférico.

Por último, mediante una inspección visual se seleccionaron las imágenes que contenían una cobertura nubosa que cubriesen gran parte de la ciudad de València, dado que no ofrecerían ningún resultado relevante y solo ensuciarían el resultado obtenido, este proceso se justifica en el apartado de enmascaramiento de nubes donde se explica cómo afectan las nubes a las mediciones de AOD.

Fecha imágenes 2018	Útil
05/02/2018	NO
10/02/2018	NO
15/02/2018	SI
20/02/2018	SI
25/02/2018	SI
01/05/2018	NO
06/05/2018	NO
11/05/2018	SI
16/05/2018	NO
21/05/2018	SI
26/05/2018	SI
31/05/2018	SI
04/08/2018	SI
09/08/2018	SI
14/08/2018	SI
19/08/2018	SI
24/08/2018	SI
29/08/2018	SI
02/11/2018	NO
07/11/2018	SI
12/11/2018	NO
17/11/2018	NO
22/11/2018	NO
27/11/2018	SI

Tabla 3. Filtrado de imágenes de 2018, fuente: elaboración propia

Fecha imágenes 2019	Útil
05/02/2019	SI
10/02/2019	NO
15/02/2019	NO
20/02/2019	SI
25/02/2019	SI
01/05/2019	NO
06/05/2019	SI
11/05/2019	SI
16/05/2019	NO
21/05/2019	NO
26/05/2019	SI
31/05/2019	SI
04/08/2019	SI
09/08/2019	SI
14/08/2019	SI
19/08/2019	SI
24/08/2019	SI
29/08/2019	NO
02/11/2019	NO
07/11/2019	NO
12/11/2019	SI
17/11/2019	NO
22/11/2019	NO
27/11/2019	NO

Tabla 4. Filtrado de imágenes de 2019, fuente: elaboración propia

Fecha imágenes 2020	Útil
05/02/2019	NO
10/02/2019	SI
15/02/2019	SI
20/02/2019	SI
25/02/2019	SI
05/05/2019	SI
10/05/2019	SI
15/05/2019	NO
20/05/2019	SI
25/05/2019	NO
30/05/2019	SI
03/08/2019	NO
08/08/2019	NO
13/08/2019	SI
18/08/2019	SI
23/08/2019	SI
28/08/2019	SI
01/11/2019	SI
06/11/2019	NO
11/11/2019	SI
16/11/2019	NO
21/11/2019	SI
26/11/2019	NO

Tabla 5. Filtrado de imágenes de 2020, fuente: elaboración propia

Fecha imágenes 2021	Útil
04/02/2019	NO
09/02/2019	NO
14/02/2019	NO
19/02/2019	SI
24/02/2019	NO
05/05/2019	NO
15/05/2019	NO
20/05/2019	SI
25/05/2019	NO
30/05/2019	SI
03/08/2019	NO
08/08/2019	NO
13/08/2019	SI
18/08/2019	NO
23/08/2019	NO
28/08/2019	SI
01/11/2019	SI
06/11/2019	SI
11/11/2019	NO
16/11/2019	SI
21/11/2019	NO
26/11/2019	SI

Tabla 6. Filtrado de imágenes de 2021, fuente: elaboración propia

5. METODOLOGÍA

La idea principal sobre la que se desarrolla la metodología es distinguir la reflectancia de los aerosoles de la reflectancia medida en el satélite, dicha reflectancia es la suma de las reflectancias de los aerosoles, del suelo y de las moléculas. La reflectancia molecular se puede determinar de forma sencilla por su gran efecto en las bandas visibles del espectro, se elimina su efecto en función de la elevación y el ángulo solar de la imagen, tal como se muestra en el estudio [7]. Por lo cual lo más importante es determinar la reflectancia del suelo.

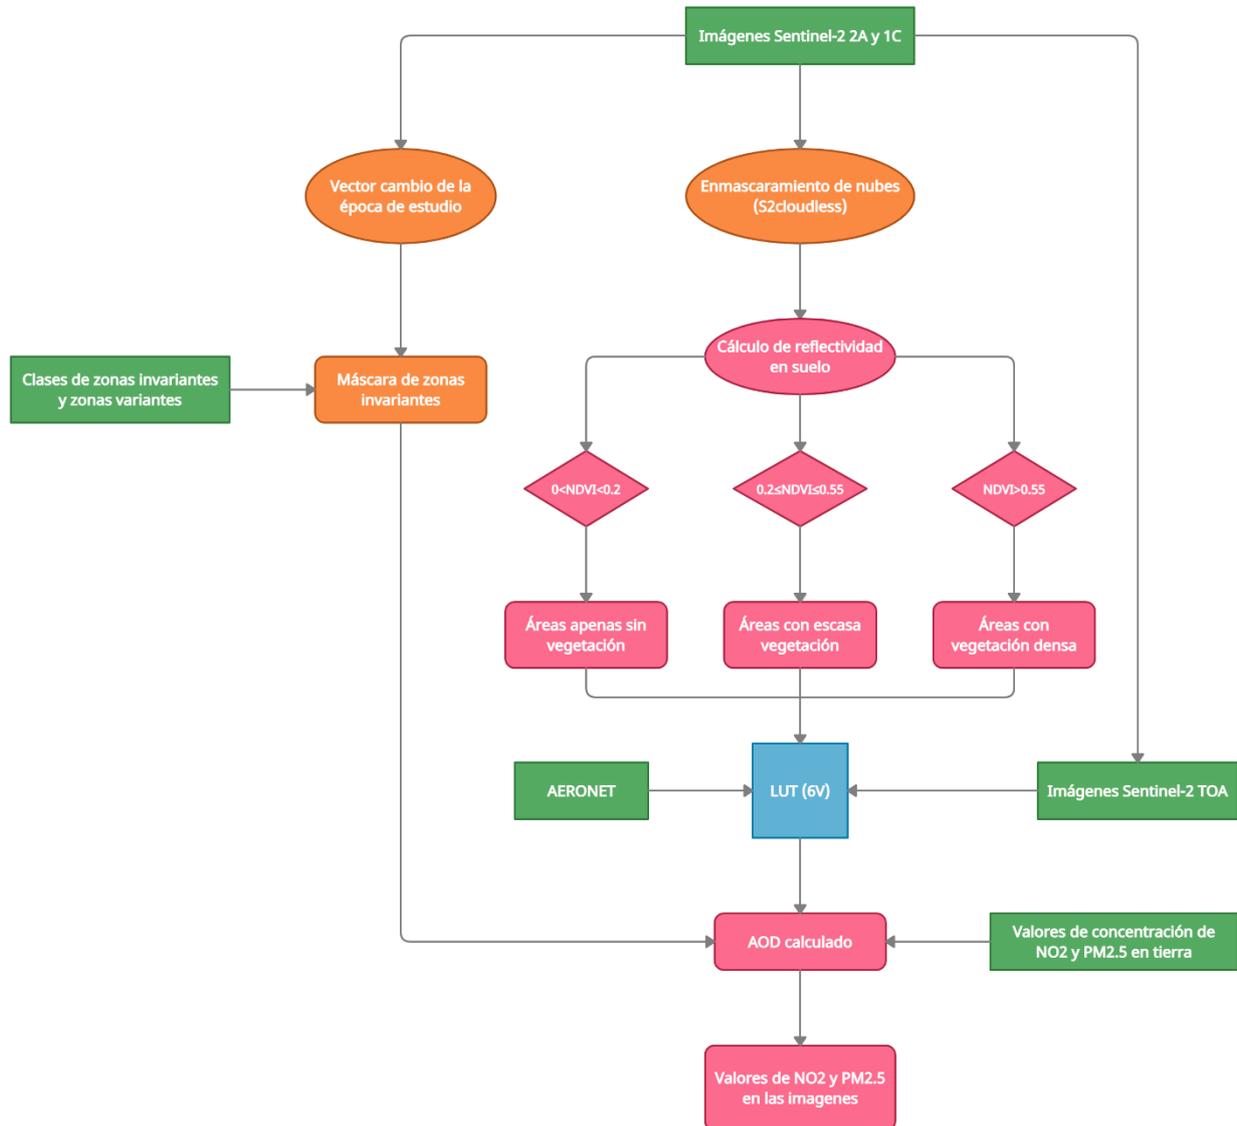


Ilustración 3. Organigrama del trabajo de investigación, fuente: elaboración propia

La metodología del trabajo de investigación en el que se incluye el proyecto es el que se observa en la Ilustración 3. De los pasos a realizar que se muestran, en el proyecto se trabajan con la obtención de las imágenes, el enmascaramiento de las nubes y la obtención de la máscara de zonas invariantes.

Esta metodología consiste en la realización de una corrección atmosférica de las imágenes 1C descargadas mediante un modelo de transmisión radiante (RTM), en este caso el modelo 6SV, generada por Look-up tables (LUT). Para la generación de dichas LUT se necesitan ciertas variables iniciales que describan la situación atmosférica, la composición de los aerosoles en la atmósfera y la situación geométrica del satélite en el momento de toma de las imágenes. Los valores de las variables geométricas se obtienen de los metadatos de las propias imágenes y la situación atmosférica a través de valores de distintas variables que se obtienen de la estación de AERONET que se encuentra en Burjassot.

Sin embargo, las reflectancias en suelo se necesitan que sean lo más precisas posibles porque su variabilidad afecta en gran medida al resultado, por lo tanto como se muestra en el artículo [4] en las ciudades que tienen un gran variedad de superficies se dividen en tres los tipos de suelo para calcular su reflectancia. Para cada imagen se pondrá como valores constantes todas las variables exceptuando el AOD, que será un rango de valores (típicos de la zona de València) y todos los resultados posibles se compararán con las imágenes nivel 2A descargadas dado que ya se encuentran corregidas atmosféricamente y se elegirá la opción más parecida mediante el método de mínimos cuadrados, de la opción resultante se rescatará su valor de AOD utilizado.

5.1. Enmascaramiento de nubes

En el apartado de descarga de imágenes se ha comentado que se ha realizado un filtrado de imágenes, esto es debido a que el AOD se mide en el rango de longitud de onda del espectro visible de la luz, en consecuencia la luz se vería reflejada en la corona de las nubes afectando a los valores medidos y se obtendrían valores de AOD muy elevados. Respecto al resto de imágenes, se deberán eliminar las nubes que contengan para asegurar la integridad de los valores de AOD resultantes del trabajo.

Existen múltiples posibilidades para el enmascaramiento de nubes y se ha estudiado cuál sería la mejor opción para el proyecto. La primera posibilidad que se ha estudiado es el producto de enmascaramiento que ofrecen las imágenes 2A de Sentinel-2 generado mediante Sen2Cor tal y como se explica en los artículos [7,8]. Sen2cor utiliza cuatro umbrales fijos en las bandas que se nombran en los artículos para definir una máscara de probabilidad en cada una, que después se multiplica entre sí para obtener una máscara de probabilidad global, dicha máscara se termina dividiendo en tres diferentes:

- Máscara de poca probabilidad
- Máscara de probabilidad media
- Máscara de probabilidad alta

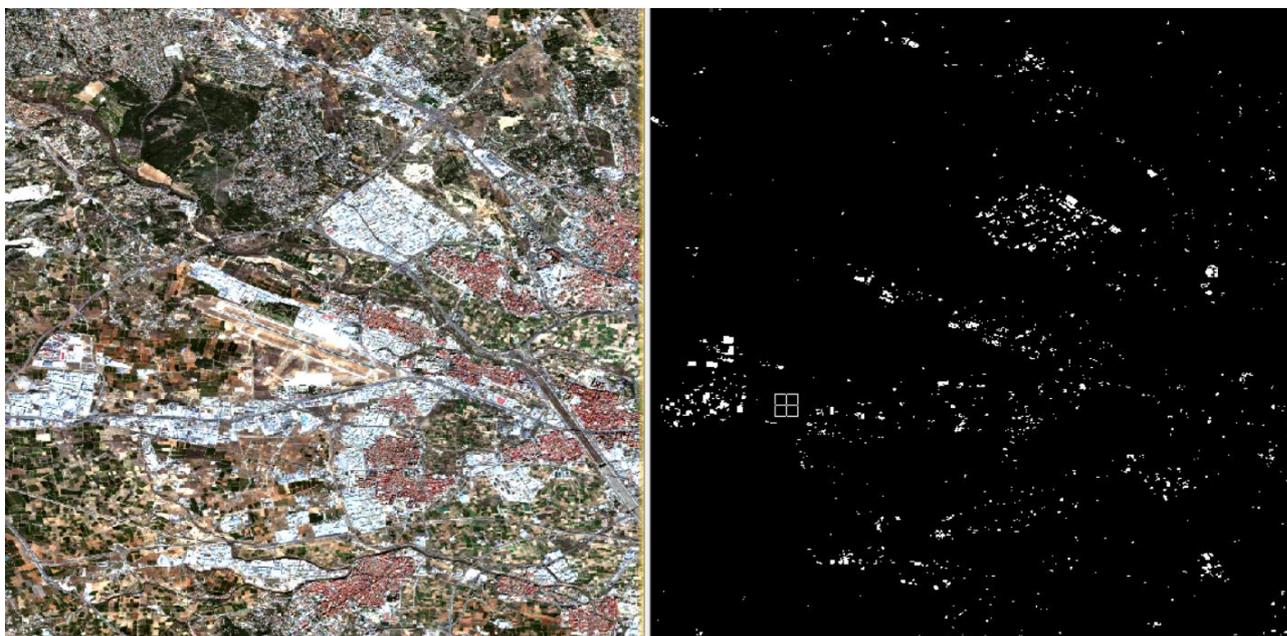


Ilustración 4. Ejemplo máscara de nubes Sen2cor, fuente: elaboración propia

Sin embargo, este producto se ha descartado debido a que por las bandas usadas en el proceso tienen una resolución comprendida entre 20-60 m, por lo tanto las nubes más pequeñas no se detectan y se crean efectos de dientes de sierra en varias de ocasiones. En la ilustración 5 se observa que en la imagen a pesar de no tener nubes se siguen clasificando muchas zonas como tal.

La segunda posibilidad estudiada es el algoritmo Fmask4.3, la última versión publicada (<https://github.com/gersl/fmask>, 10 de septiembre de 2021), en un principio el algoritmo Fmask estaba desarrollado para su uso en imágenes Landsat 8 pero esta última versión se puede utilizar también en imágenes Sentinel-2 como muestran en los artículos [9,10]. Este método primero calcula las capas de sombras de nubes y nubes a partir de unos umbrales de fecha única. A continuación se obtiene la probabilidad de nube potencial a partir de las estadísticas calculadas de los píxeles que no son considerados nubes y aquellos que tengan mayor probabilidad también se incluyen. El último paso es mediante un método basado en objetos, segmentar las capas de nube potencial e intentar hacer coincidir las nubes con sus sombras, para detectar las sombras de nubes.

Por último, se contempló un enmascaramiento automático a todas las imágenes utilizadas mediante s2cloudless a través de Google Earth Engine (GEE). En el proyecto se apostó por el uso de s2cloudless porqué a diferencia de Fmask4.3 o Sen2cor este algoritmo no aplica un umbral para clasificar los píxeles como nubes, sino que asigna una probabilidad a cada píxel de ser parte de una nube. Se escogió esta opción por su versatilidad para poder ser tan restrictivo en el enmascaramiento como se quiera en función de las necesidades del estudio. El código de s2cloudless permite detectar nubes en función de su probabilidad, seleccionar un área de influencia alrededor de las nubes lo que es útil para evitar que píxeles que a priori no parezcan parte de la nube pero se vean influenciados por la misma no sean eliminados, y las sombras que producen las nubes dado que afectan a la reflectividad obtenida del suelo.

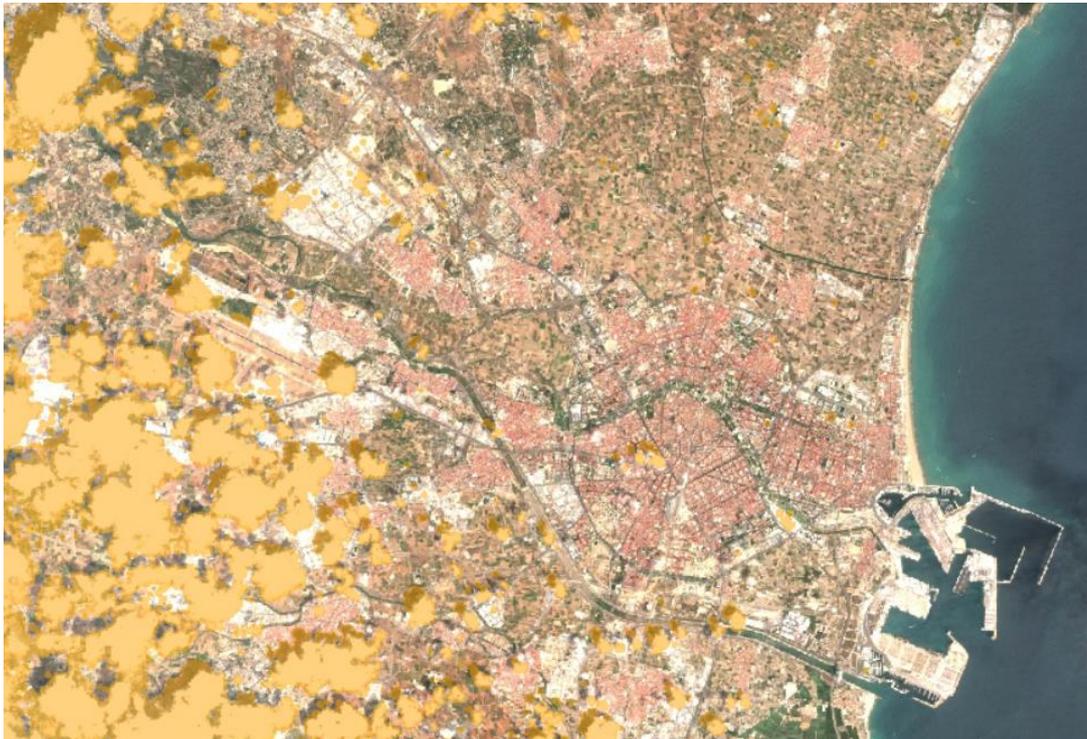


Ilustración 5. Ejemplo de enmascaramiento mediante S2cloudless, fuente: elaboración propia

Tras realizar unas pruebas con distintos parámetros en las imágenes del proyecto se decidió utilizar la configuración que se muestra en la ilustración 3, donde el parámetro “CLD_PRB_THRESH” es la probabilidad de que un píxel sea una nube, “CLD_PRJ_DIST” es la distancia máxima en kilómetros a la que se busca la sombra de una nube, “BUFFER” es el área de interés en metros que se aplica. En el proyecto se ha determinado como nube aquellos píxeles que muestren un 30% de probabilidad o más, se ha escogido este valor tras realizar unas pruebas con imágenes del proyecto con el fin de ser restrictivo y asegurar que la gran mayoría de nubes se enmascaren, sin eliminar una gran parte de píxeles que no son nubes. Estas diferencias se pueden observar en las siguientes ilustraciones las cuales corresponden a la misma imagen con diferentes probabilidades. En la ilustración 7, donde se aplica un 10%, en la ilustración 8 donde se aplica un 30% y en la ilustración 9 un 50%.

```
AOI = ee.Geometry.Point([-0.3780581331738131, 39.471157945104885])
START_DATE = '2020-06-09'
END_DATE = '2020-06-10'
CLOUD_FILTER = 60
CLD_PRB_THRESH = 30
NIR_DRK_THRESH = 0.15
CLD_PRJ_DIST = 1
BUFFER = 70
```

Ilustración 6. Parámetros usados en S2cloudless, fuente: elaboración



Ilustración 7. Máscara con probabilidad del 10%, fuente: elaboración propia



Ilustración 9. Máscara con probabilidad del 30%, fuente: elaboración propia

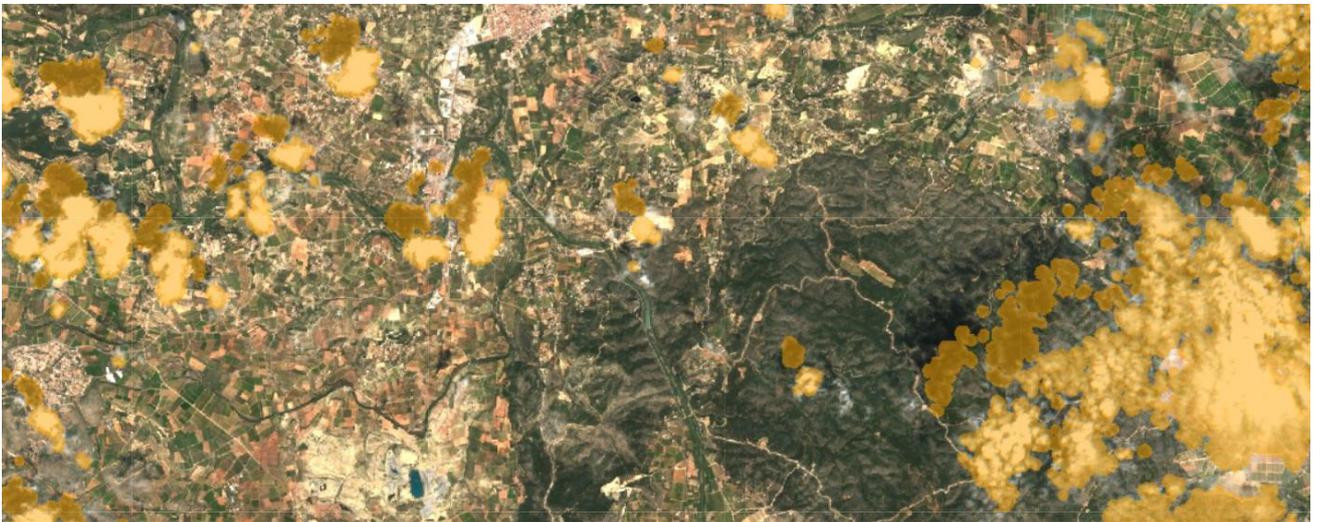


Ilustración 8. Máscara con probabilidad del 50%, fuente: elaboración propia

Como se puede observar en las ilustraciones anteriores, con una máscara del 10% se han eliminado todas las nubes, pero se observa en como por ejemplo en la parte inferior de la imagen muchos píxeles han sido enmascarados como nubes sin embargo no lo son. Por otro lado, con una probabilidad del 30% se muestra un buen enmascaramiento casi en totalidad de las nubes y el número de píxeles confundidos con nubes prácticamente es nulo. Por último, con la probabilidad del 50% las nubes se detectan bastante peor como se puede observar en la parte superior derecha que deja parte de la nube sin detectar mientras que con la probabilidad del 30% queda enmascarada en gran medida.

5.2. Detección de zonas invariantes

Una vez determinados los valores de AOD en las imágenes se quiere estudiar su variación en el periodo de tiempo del proyecto, la mejor forma para ello es observar dichas variaciones en zonas que no hayan cambiado en el tiempo, es decir zonas que no haya variado sus construcciones o su uso de suelo. Por lo tanto, se deben de determinar estas zonas invariantes y con este fin se va a utilizar el método del vector de cambios de la zona como se aplica en el artículo [11], usando una imagen del 15/02/2018 del inicio del periodo y otra imagen del 19/02/2021 del final del periodo.

El método de detección del vector de cambios consiste en la definición del módulo y la dirección del vector que une los valores de los píxeles en un espacio definido por dos bandas espectrales de distinta fecha. En este método el vector se conforma por el módulo, el cual muestra la magnitud del cambio y la dirección, la cual muestra el tipo de cambio que se produce.

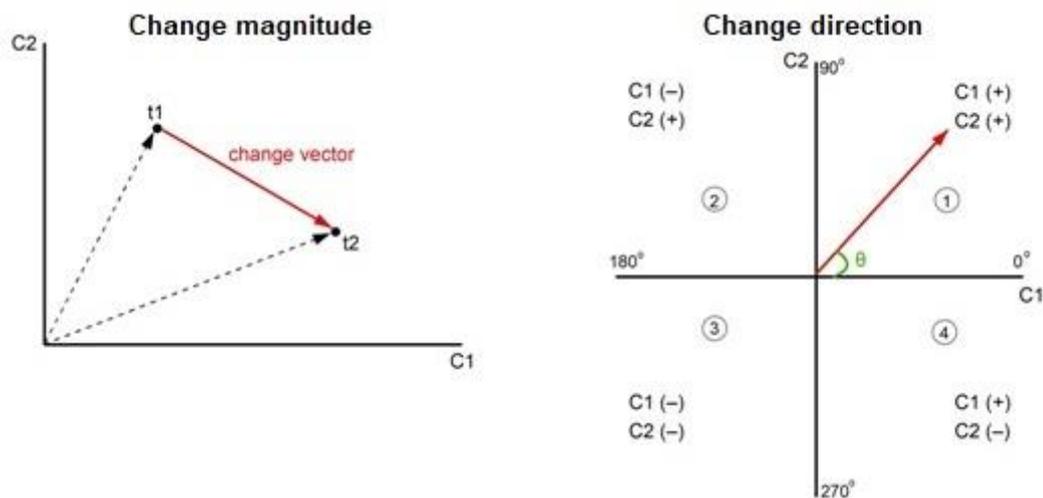


Ilustración 10. Vector cambio, fuente: elaboración propia

Como se ha comentado en el párrafo anterior para determinar dicho vector de cambio hace falta definir un espacio conformado por dos bandas, pero no tiene sentido escoger cualquier banda. Deben de ser dos bandas óptimas para la diferenciación de cambios a raíz de su respuesta espectral, por lo tanto teniendo en cuenta este hecho se han escogido la banda del rojo y del NIR (Infrarrojo cercano) de Sentinel-2, se han escogido estas porque tal como se observa en la

Ilustración 11 el mayor contraste de señales se obtiene en el cambio de rojo a NIR.

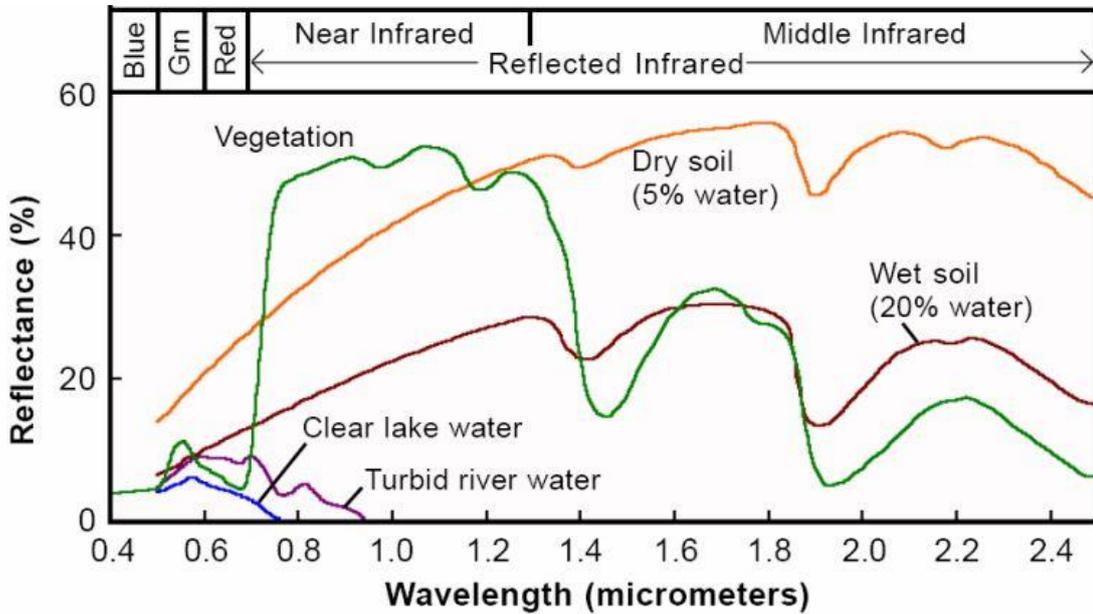


Ilustración 11. Respuesta espectral de diferentes tipos de suelo, fuente: "<https://gidahatari.com/ih-es/tutorial-determinación-de-huellas-espectrales-de-cobertura-de-suelos-con-qgis-3-y-scp-6>"

En la obtención del módulo hay que calcular los incrementos de valor espectral en cada banda entre las dos fechas y con los incrementos el módulo tal y como se observan en las ecuaciones siguientes:

$$\Delta x = im2021_{B4} - im2018_{B4} \quad (1)$$

$$\Delta y = im2021_{B8} - im2018_{B8} \quad (2)$$

$$Módulo = \sqrt{\Delta x^2 + \Delta y^2} \quad (3)$$

Para la dirección, utilizando los incrementos anteriores se calcula el ángulo como se muestra en la ecuación 4, pero hay que tener en cuenta que de esta forma no se calculan los ángulos en sus cuadrantes correspondientes, con este fin utilizando un par de condicionales y teniendo en cuenta los signos de los incrementos. Tal y como se muestra en la ilustración 10 se puede adecuar los valores para que el ángulo del vector cambio varíe entre 0° y 360°.

$$Dirección = \tan^{-1} \frac{\Delta x}{\Delta y} \quad (4)$$

Una vez obtenidos los valores del módulo y dirección anteriores se puede crear una imagen en el espacio de color HSI, en esta representación H (tono) correspondería con la dirección del vector cambio y sus valores para una buena

representación deben encontrarse entre 0° y 360°, el parámetro I (intensidad) se correspondería con el módulo y sus valores deberán variar entre 0 y 1, por lo tanto los valores obtenidos anteriormente se le aplica un reescalado mediante una transformación lineal. Por último, S (saturación) se establece como valor contante de 1. Para poder interpretar los resultados de manera visual se realiza una transformación de espacio de color de HSI a RGB utilizando para ello las ecuaciones que aparecen a continuación siempre y cuando los valores de HSI tengan el formato que se indicó anteriormente.

$$x = i * (1 - s) \quad (5)$$

$$y = i * \left[1 + \frac{s * \cos(h)}{\cos\left(\frac{\pi}{3} - h\right)} \right] \quad (6)$$

$$z = 3i - (x + y) \quad (7)$$

Cuando $h < 2\pi/3$, $r=y$; $g=z$ y $b=x$

Cuando $2\pi/3 \leq h < 4\pi/3$, $h=h-2\pi/3$, $r=x$; $g=y$ y $b=z$

Cuando $4\pi/3 \leq h < 2\pi$, $h=h-4\pi/3$, $r=z$; $g=x$ y $b=y$

De esta forma se obtuvo una imagen de cambios en la cual cada tono representa un tipo de cambio y el brillo o la intensidad está relacionada con la magnitud de cambio. Sin embargo, la finalidad de aplicar este método es obtener una clasificación de la imagen de zonas invariante y zonas invariantes, con este fin se busca determinar un valor umbral en la banda módulo del vector cambio en el que cualquier valor inferior se considere como invariante, dado que valores pequeños en esta banda significa que no existe cambio o es muy reducido.

Para conseguir esta premisa, se definieron dos clases distintas tomando muestras observando ambas imágenes. Por un lado, para la clase de zonas invariantes, se crearon distintas muestras en zonas que en ambas imágenes eran invariantes, es decir no habían cambiado. Por otro lado, para la clase de zonas variantes se repitió el proceso tomando muestras de zonas que hubieran sufrido cambios entre ambas imágenes. Estas clases se crean con el fin de obtener sus medias y desviaciones típicas, las cuales se muestran en la tabla 7.

Clase	Media	Desviación
Zona invariante	446.5458	497.1403
Zona Variante	3607.9567	2283.5147

Tabla 7. Estadísticas de las clases, fuente: elaboración propia

Con las estadísticas de ambas clases se pueden representar ambas distribuciones normales asociadas a cada una con el fin de encontrar el punto de intersección de ambas distribuciones, el cual será el umbral utilizado para la selección de zonas invariantes, en este caso la intersección se produce en el valor 1435.1644.

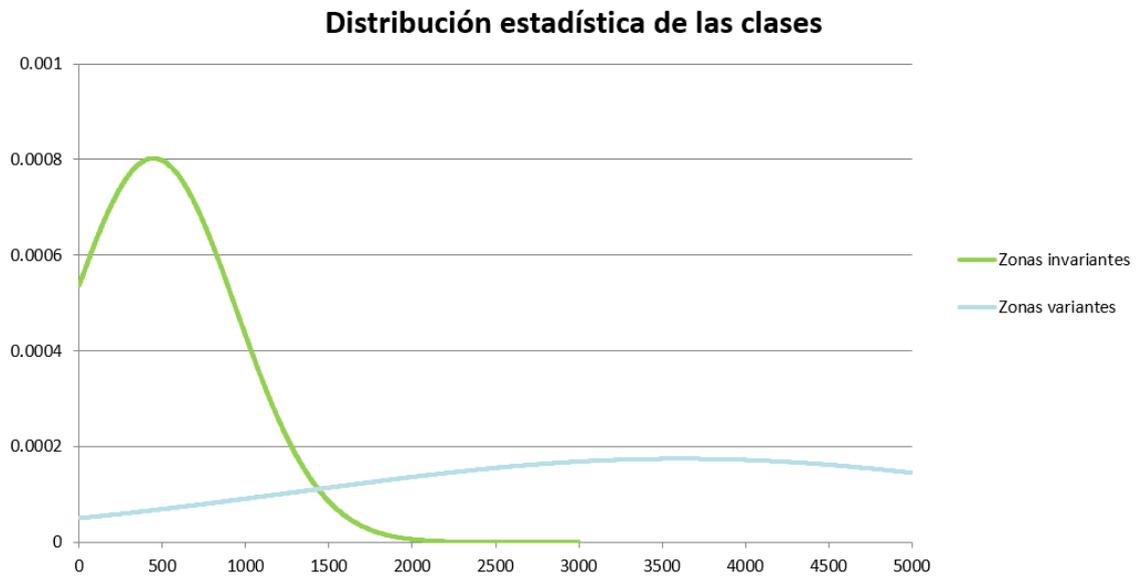


Ilustración 12. Distribución normal de las clases, fuente: elaboración propia

6. RESULTADOS

En este proyecto se pueden dividir los resultados obtenidos en tres, el enmascaramiento de nubes mediante s2cloudless, el estudio visual del cambio de reflectancia en la zona de estudio mediante la combinación RGB de los elementos del vector cambio y por último la determinación de las zonas invariantes.

Respecto al enmascaramiento de nubes se muestran varios de ejemplos de los resultados obtenidos en el apartado de cartografía y el código de GEE utilizado se muestra en el apartado de anexos. El sistema utilizado como se ha comentado anteriormente muestra un buen equilibrio entre la detección de nubes y no eliminar demasiada información que no son parte de una nube o su área de influencia.

Respecto a la imagen RGB de cambios definida a través del vector cambio se puede observar de forma sencilla los cambios que se han producido en este tiempo en función de los tonos de la imagen, a continuación se muestran algunos ejemplos visualizados de cada tono mostrando la imagen del 2018, la imagen de 2021 y la imagen de cambios para observar de forma sencilla el cambio en el tiempo.

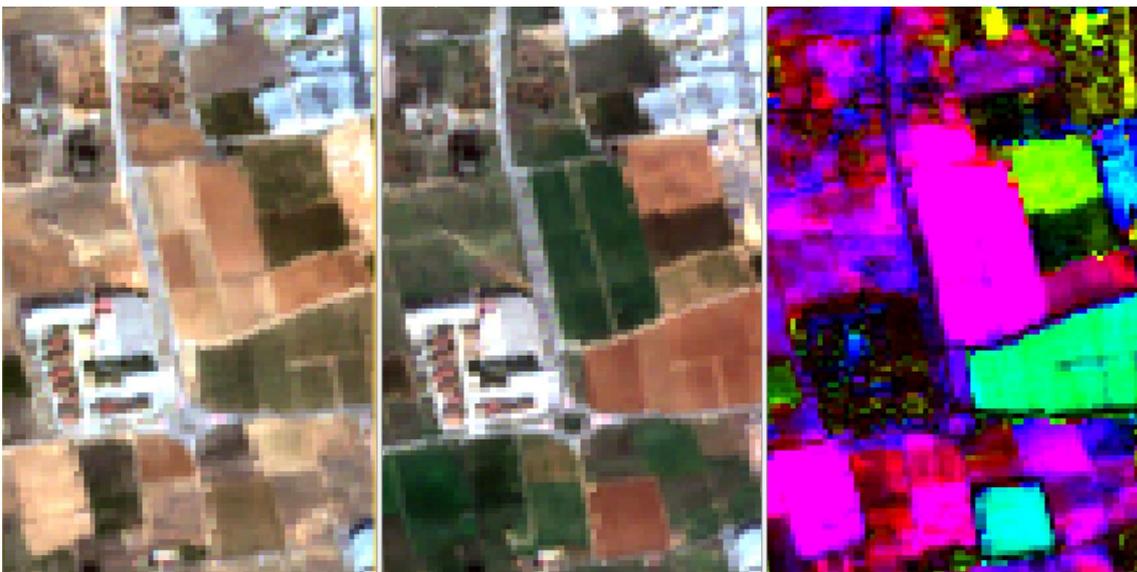


Ilustración 13. Ejemplo1 del tono de cambio magenta, fuente elaboración propia

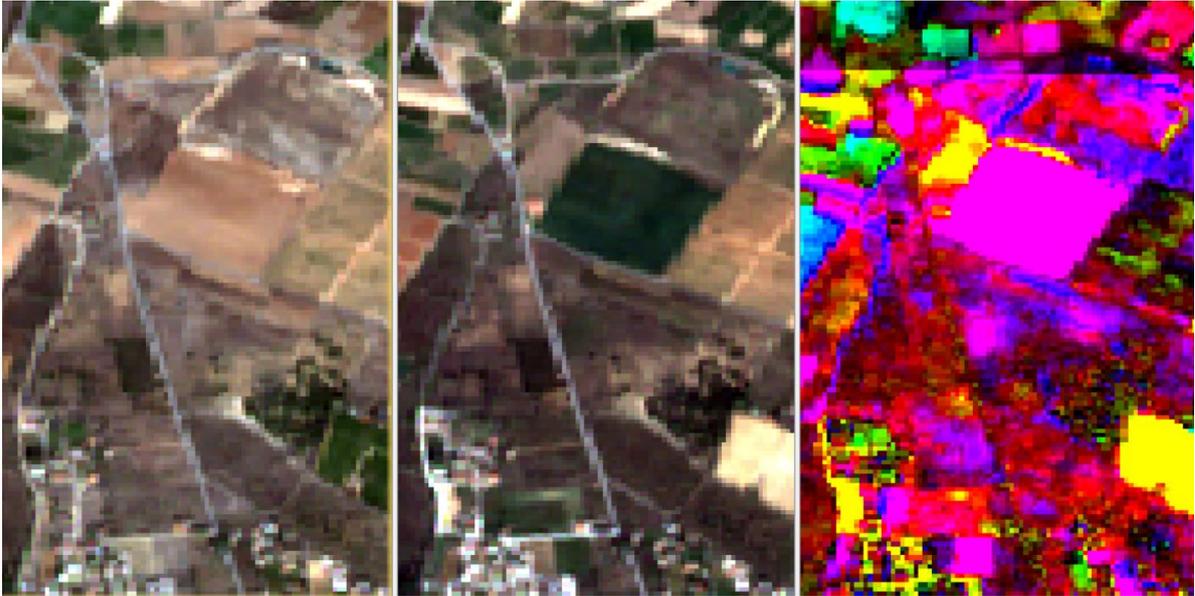


Ilustración 14. Ejemplo 2 del tono de cambio magenta, fuente: elaboración propia

En las ilustraciones anteriores se observan a la vez tres imágenes, a la izquierda la imagen de la fecha de 2018, en medio la imagen 2019 y a la derecha la imagen de cambios. Teniendo en cuenta este orden se puede observar en los dos ejemplos expuestos que en color magenta se muestra los aumentos de vegetación. El grado de intensidad de dicho tono depende del grado de aumento de la vegetación y la señal del suelo si se parte de un suelo desnudo.

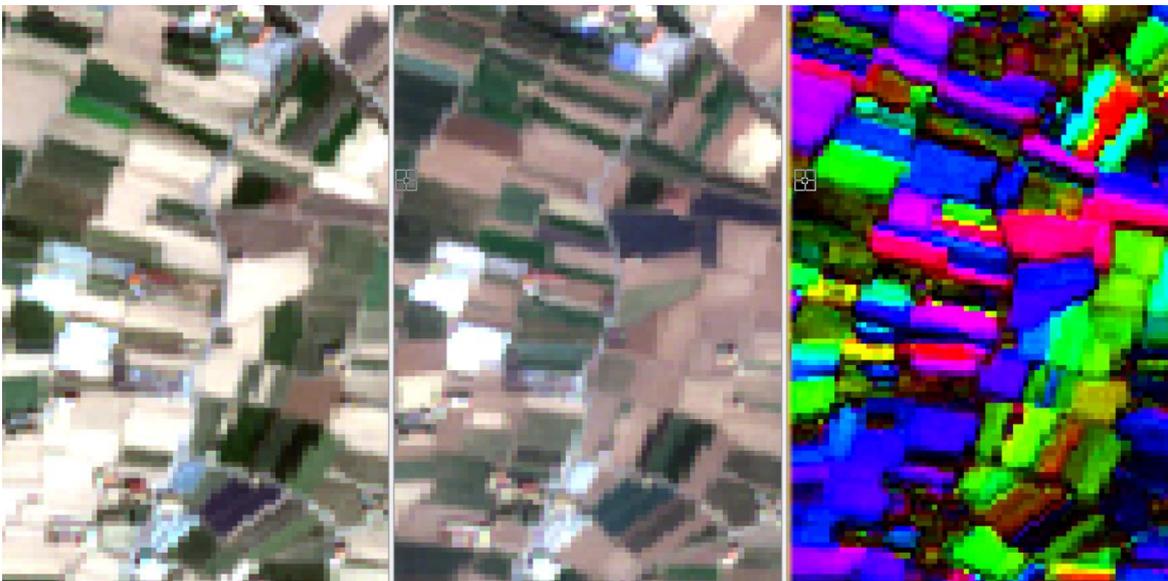


Ilustración 15. Ejemplo 1 del tono de cambio azul, fuente: elaboración propia

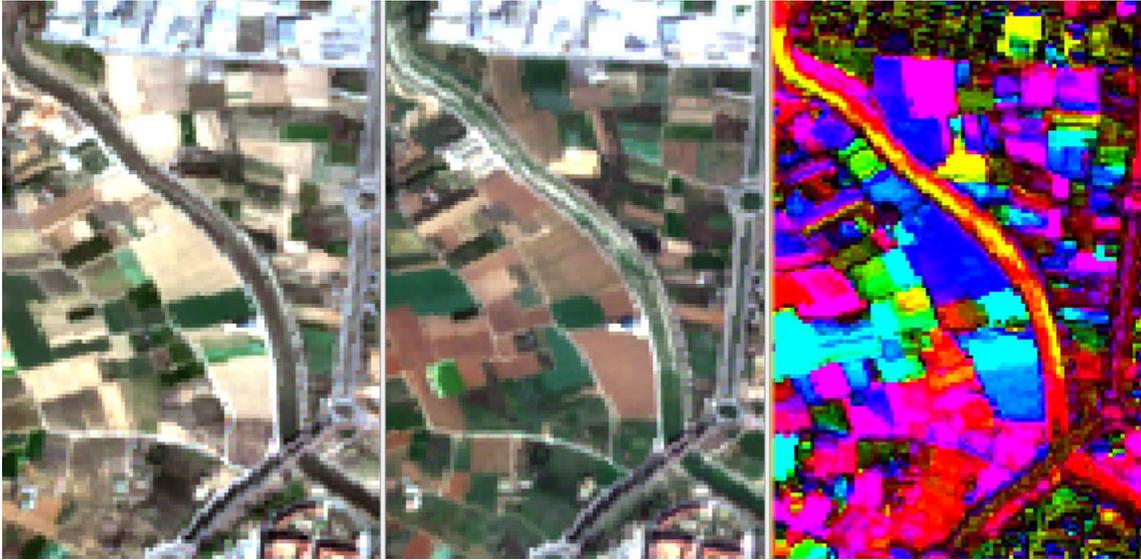


Ilustración 16. Ejemplo 2 del tono de cambio azul, fuente: elaboración propia

Para el análisis del tono azul se ha seguido la misma metodología anterior con las imágenes. Por lo tanto, como se puede observar en los ejemplos facilitados el cambio que muestra el tono azul es una disminución de la reflectividad, debido a que en estos ejemplos se observa un cambio de suelo desnudo brillante a un suelo desnudo con una señal menor y por lo tanto más oscuro.

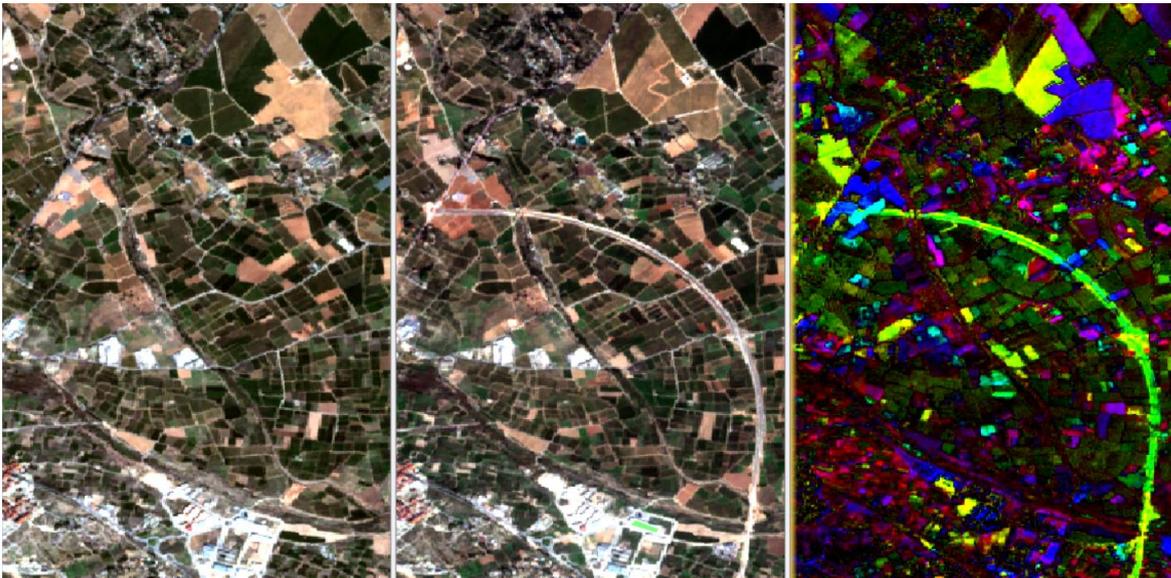


Ilustración 17. Ejemplo 1 del tono de cambio amarillo, fuente: elaboración propia



Ilustración 18. Ejemplo 2 del tono de cambio amarillo, fuente: elaboración propia

Como en los casos anteriores, se ha utilizado la misma distribución en las imágenes. En este caso se estudia el tono amarillo, de este tono se observa en ambos ejemplos que el cambio ha sido de zona no construida a zona construida. Pero, en el ejemplo 1 en la parte superior también se pueden observar un par de parcelas con el mismo tono. En el caso de las parcelas, se observa que el cambio es el paso de una parcela con vegetación a un suelo desnudo, en consecuencia el tono amarillo se debe a un descenso en la vegetación.

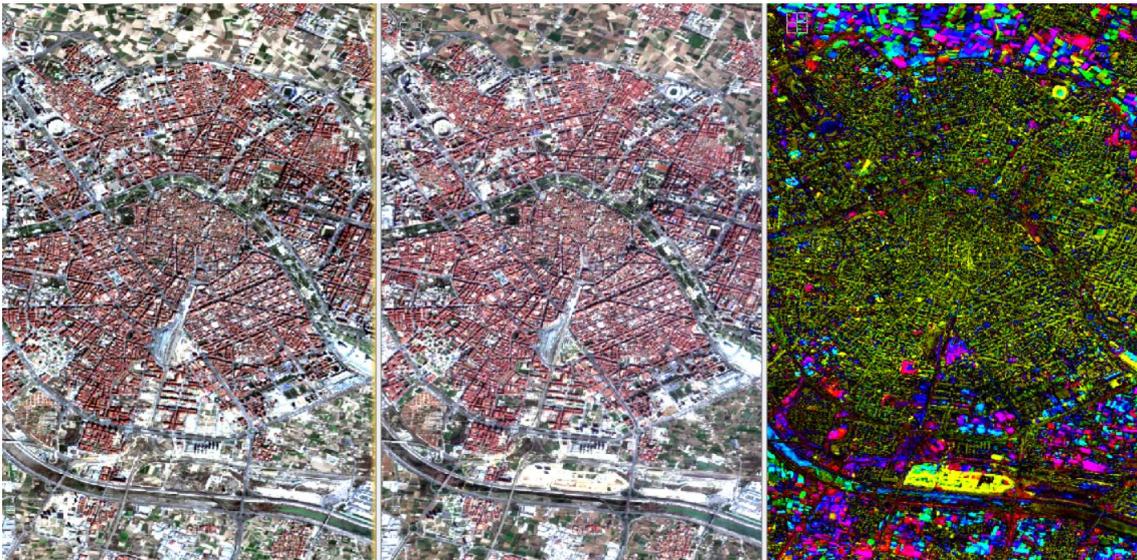


Ilustración 19. Ejemplo del tono de cambio verde, fuente: elaboración propia

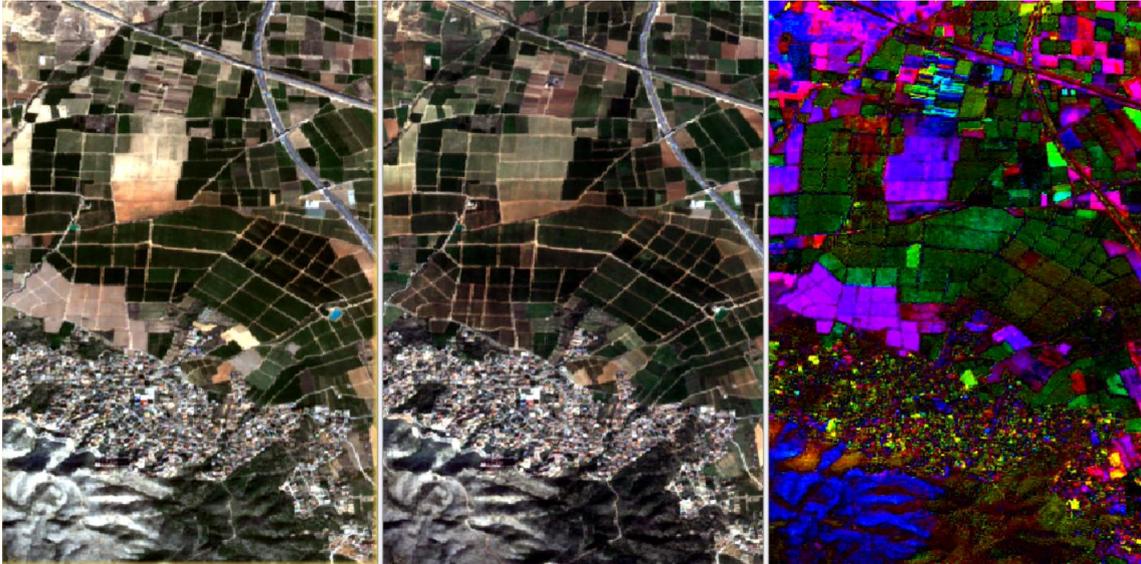


Ilustración 20. Ejemplo 2 del tono de cambio verde, fuente: elaboración propia

Por último, se estudia el tono verde el cual se visualiza a lo largo de la imagen en las zonas urbanas como la ciudad de Valencia y en los cultivos que no han sufrido una variación aparentemente visible entre las dos imágenes como se muestra en uno de los ejemplos expuestos. Aunque cabe destacar que el verde de ambos casos tiene intensidades diferentes por lo que no muestran al 100% la misma situación. Aparentemente el tono verde muestra una variación casi nula de la reflectividad.

Para concluir, la máscara de zonas invariantes que está presente en el apartado de cartografía y como se muestra en la ilustración 21. Se observa que gran parte de la imagen ha sido clasificada como zona invariante y las variaciones más marcadas no se han incluido en la máscara, como se observa en la ilustración 22.

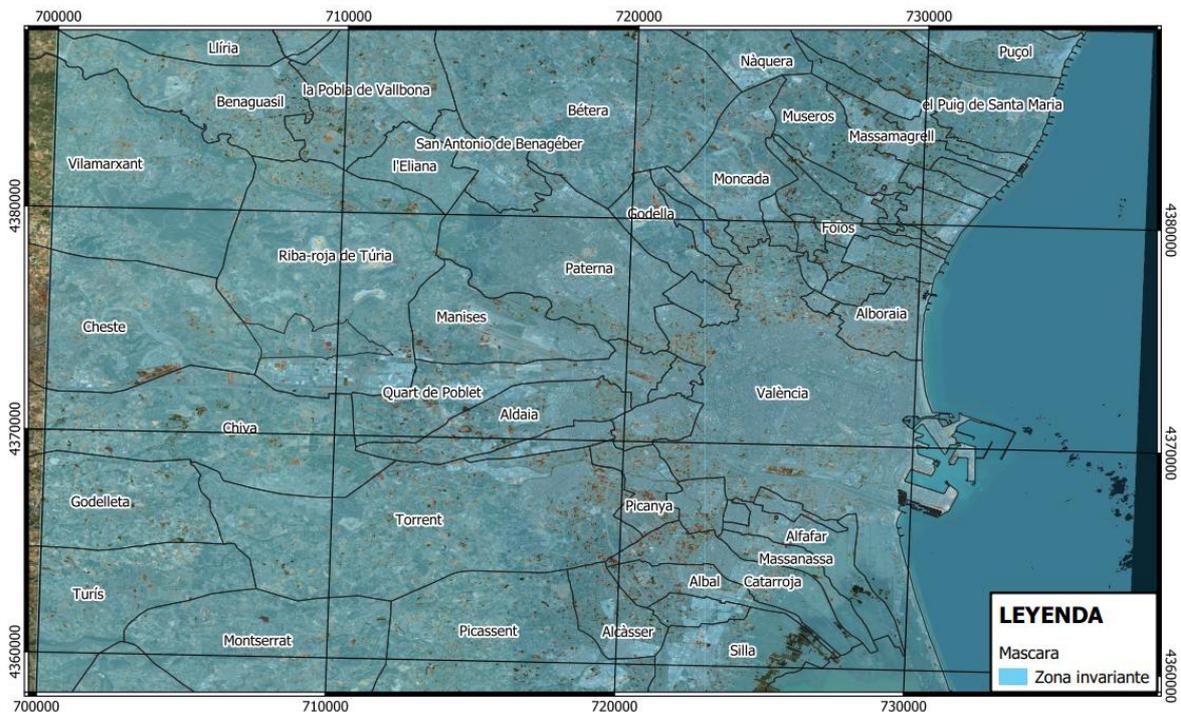


Ilustración 21. Mapa de máscara de zonas invariantes, fuente: elaboración propia

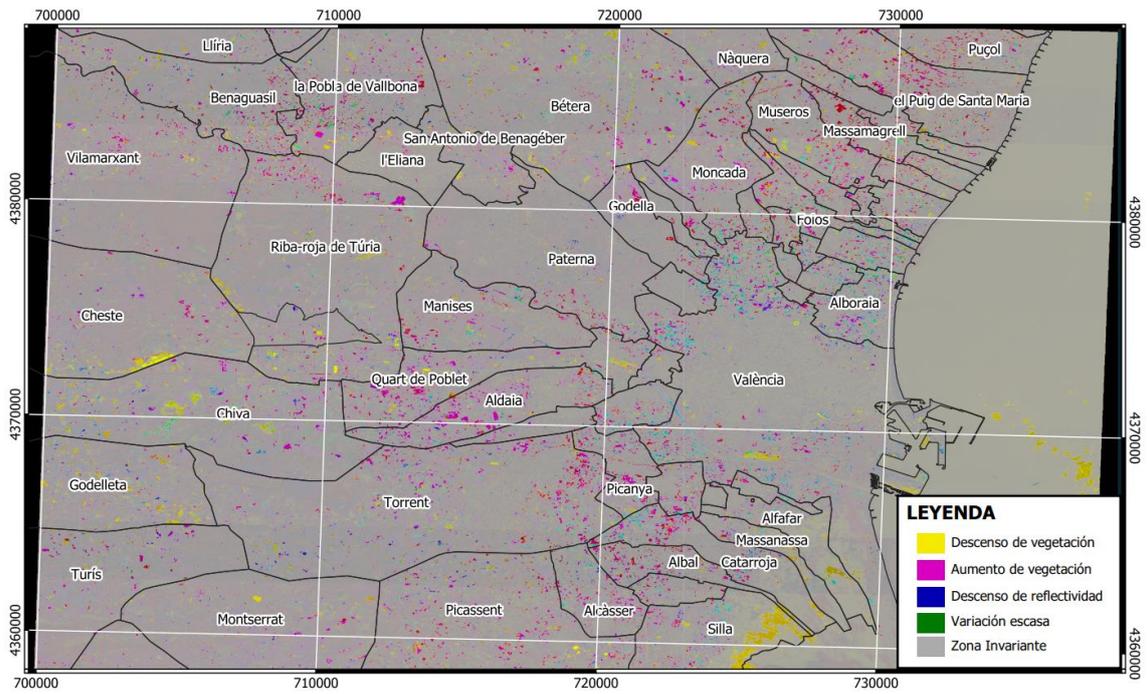


Ilustración 22. Mapa de zonas invariantes superpuesto con las zonas de cambio, fuente: elaboración propia

7. PRESUPUESTO

Para el presupuesto, en relación con los recursos humanos del proyecto se parte del convenio de ingenieros y oficina técnica más actual el cual corresponde al año 2020. Los niveles de los trabajadores y su remuneración correspondiente se muestran en la ilustración (X).

Niveles	Tabla salarial según art. 33		Plus convenio anual según art. 38 convenio	Total anual	
	Mes x 14	Anual			
1	LICENCIADOS Y TITULADOS 2.º Y 3.º CICLO UNIVERSITARIO Y ANALISTA	1.712,42	23.973,88	2.349,69	26.323,57
2	DIPLOMADOS Y TITULADOS 1.º CICLO UNIVERSITARIO. JEFE SUPERIOR	1.291,04	18.074,56	2.349,69	20.424,25
3	TÉCNICO DE CÁLCULO O DISEÑO, JEFE DE 1.º Y PROGRAMADOR DE ORDENADOR	1.244,93	17.429,02	2.349,69	19.778,71
4	DELINEANTE-PROYECTISTA, JEFE DE 2.º Y PROGRAMADOR DE MAQ. AUXILIARES	1.141,36	15.979,04	2.349,69	18.328,73
5	DELINEANTE, TÉCNICO DE 1.º, OFICIAL 1.º ADMTVO. Y OPERADOR DE ORDENADOR	1.019,82	14.277,48	2.349,69	16.627,17
6	DIBUJANTE, TÉCNICO DE 2.º, OFICIAL 2.º ADMTVO., PERFORISTA, GRABADOR Y CONSERJE	878,63	12.300,82	2.349,69	14.650,51
7	TELEFONISTA-RECEPCIONISTA, OFICIAL 1.º OFICIOS VARIOS Y VIGILANTE	849,16	11.888,24	2.349,69	14.237,93
8	AUXILIAR TÉCNICO, AUX. ADMTVO., TELEFONISTA, ORDENANZA, PERSONAL DE LIMPIEZA Y OFICIAL 2.º OFICIOS VARIOS	790,36	11.065,04	2.349,69	13.414,73
9	AYUDANTE OFICIOS VARIOS	757,29	10.602,06	2.349,69	12.951,75

Ilustración 23. Salarios convenio de ingenieros y oficina técnica, fuente: BOE-A-2019-14977

Del trabajo realizado en este proyecto que se engloba en un trabajo de investigación solamente he trabajado yo por lo tanto solo hay que tener en cuenta un trabajador de nivel 2, diplomados y titulados 1.º ciclo universitario. Jefe superior. Con esto en mente cada día de trabajo tiene el siguiente coste:

Trabajadores	Salario mensual	Salario anual	Plus convenio	Total anual
Ingeniero en Geomática y topografía	1291.04€	18074.56€	2349.69€	20424.25€

Tabla 8. Remuneración de los trabajadores por el convenio de ingenieros y oficina técnica, fuente: elaboración propia

Trabajadores	Seguridad social	Coste total	Coste diario
Ingeniero en Geomática y topografía	8168.70€	28593.95€	129.97€

Tabla 9. Costes de los trabajadores por el convenio de ingenieros y oficina técnica, fuente: elaboración propia

Material	Licencia	Coste
GEE (Google Earth Engine)	Libre	0€
SNAP	Libre	0€
GOOGLE COLAB	Libre	0€
PYTHON	Libre	0€

Tabla 10. Coste del material utilizado, fuente: elaboración propia

Actividad	Duración	Recursos humanos	Coste de recursos humanos	Material	Coste del material	Coste total
Investigación	3 semanas	1 Ingeniero	1949.59€			1949.59€
Descarga de datos	2 semanas	1 Ingeniero	1299.73€	GEE	0€	1299.73€
Desarrollo de metodología	2 meses	1 Ingeniero	5198.90€	GEE GOOGLE COLAB PYTHON SNAP	0€	5198.90€
Total	3 meses y 1 semana	1 Ingeniero	8448.21€		0€	8448.21€

Tabla 11. Costes por actividad y totales del proyecto, fuente: elaboración propia

8. CONCLUSIONES

En este proyecto se ha realizado un estudio amplio sobre las imágenes digitales de los satélites y sus características, con el fin de realizar el mejor tratamiento posible. Teniendo esta premisa en mente se ha realizado un enmascaramiento de nubes muy eficiente tal y como se muestra en los mapas de ejemplo en el apartado de cartografía dado que eliminan una gran parte de la totalidad de las nubes pagando un mínimo precio de confusión de píxeles, lo que permite optimizar la cantidad de información que estará disponible en el estudio sin permitir que los valores erróneos o anómalos de las nubes y sus áreas de influencia predominen en el estudio.

Una posible mejora para este apartado sería realizar un enmascaramiento personalizado a cada imagen en vez de aplicar la misma probabilidad a todas las imágenes. Este aspecto es posible por el reducido número de datos a emplear, sin embargo si se replicara el proceso a gran escala sería inviable, por lo que para mejorar este punto posiblemente habría que desarrollar un código de autoaprendizaje que implementara de forma automática la mejor probabilidad de nubes a cada imagen.

Por otra parte, con el uso del método de vector cambio se ha obtenido un resultado visual con mucho valor ya que no solo muestra si se ha producido el cambio y donde, sino que gracias a su visualización RGB también se puede estudiar como es el cambio que se produce.

Por último, el cálculo de las zonas invariantes se ha realizado mediante el estudio de las zonas cambiantes como las que no lo que aporta una mayor seguridad de definición que utilizando simplemente la población de zonas invariantes, dado que permite visualizar el grado de confusión entre ambas. En este caso la utilidad y la calificación del resultado como bueno es relativa debido a que aun no se ha aplicado al resultado final para observar si debería de acotarse más las zonas invariantes o no, simplemente se puede afirmar que el proceso aplicado en este proyecto diferencia los cambios más marcados del resto de la imagen. En caso de necesitar ser más restrictivo se podría estudiar con más detenimiento la definición de las clases de zonas cambiantes y no cambiantes para de esta forma no se confundan tantos valores entre clases y se delimite mejor la zona.

9. BIBLIOGRAFÍA

1. European Court of Auditors 2018 Special report no 23/2018: airpollution: our health still insufficiently protected EuropeanCourt of Auditors Guardians of the EU's finances (www.eca.europa.eu/Lists/ECADocuments/SR18_23/SR_AIR_QUALITY_EN.pdf).
2. European Environment Agency [EEA] 2017 Air quality inEurope. No 13/2017 (Luxembourg) (<https://doi.org/10.2800/850018>).
3. Costa S, Ferreira J, Silveira C, Costa C, Lopes D, Relvas H, Borrego C, Roebeling P, Miranda A I and Teixeira J P 2014 Integrating health on air quality assessment—review report on health risks of two major European outdoor air pollutants: PM and NO₂. *Toxicol. Environ. Health* B176307–40.
4. AbdelSattar A. (2019) "Monitoring Air Pollution Using Satellite Data" proceedings of International Conference on Industrial Engineering and Operations Management (November 26-28 of 2019, Saudi Arabia), Riyadh (coord).
5. Gitahi J.; Hahn M. (2020) "High-resolution urban air quality monitoring using sentinel satellite images and low-cost ground-based sensor networks" proceedings of the 9th International Scientific-Technical Conference on Environmental Engineering, Photogrammetry, Geoinformatics – Modern Technologies and Development Perspectives (EEPG Tech 2019).
6. Lin, Hao, Siwei Li, Jia Xing, Jie Yang, Qingxin Wang, Lechao Dong y Xiaoyue Zeng. 2021. "Recuperaciones de fusión de la profundidad óptica de aerosoles de alta resolución de las observaciones de Landsat-8 y Sentinel-2 sobre áreas urbanas" *Remote Sensing* 13, no. 20: 4140. <https://doi.org/10.3390/rs13204140>
7. Patadia, F.; Levy, R.C.; Mattoo, S. Correcting for trace gas absorption when retrieving aerosol optical depth from satellite observations of reflected shortwave radiation. *Atmos. Meas. Tech.* 2018, 11, 3205–3219.
8. Baetens, L.; Desjardins, C.; Hagolle, O. Validation of Copernicus Sentinel-2 Cloud Masks Obtained from MAJA, Sen2Cor, and FMask Processors Using Reference Cloud Masks Generated with a Supervised Active Learning Procedure. *Remote Sens.* 2019, 11, 433.
9. Qiu, S.; Zhu, Z.; He, B.B. Fmask 4.0: Improved cloud and cloud shadow detection in Landsats 4-8 and Sentinel-2 imagery. *Remote Sens. Environ.* 2019, 231, 111205.
10. Zhu, Z.; Wang, S.X.; Woodcock, C.E. Improvement and expansion of the Fmask algorithm: Cloud, cloud shadow, and snow detection for Landsats 4-7, 8, and Sentinel 2 images. *Remote Sens. Environ.* 2015, 159, 269–277.
11. Ruiz Fernández, Luis Ángel [et al.]. "Frictions between heterogeneous worlds". ACE: Arquitectura, Ciudad y Entorno, 2007, Any II núm. 4.

10. ANEXOS

```
#@title Copyright 2020 The Earth Engine Community Authors { display-  
mode: "form" }  
#  
# Licensed under the Apache License, Version 2.0 (the "License");  
# you may not use this file except in compliance with the License.  
# You may obtain a copy of the License at  
#  
# https://www.apache.org/licenses/LICENSE-2.0  
#  
# Unless required by applicable law or agreed to in writing, software  
# distributed under the License is distributed on an "AS IS" BASIS,  
# WITHOUT WARRANTIES OR CONDITIONS OF ANY KIND, either express or  
implied.  
# See the License for the specific language governing permissions and  
# limitations under the License.
```

Sentinel-2 Cloud Masking with s2cloudless

Author: jdbcode

This tutorial is an introduction to masking clouds and cloud shadows in Sentinel-2 (S2) surface reflectance (SR) data using Earth Engine. Clouds are identified from the S2 cloud probability dataset (s2cloudless) and shadows are defined by cloud projection intersection with low-reflectance near-infrared (NIR) pixels.

For a similar JavaScript API script, see this [Code Editor example](#).

Run me first

Run the following cell to initialize the Earth Engine API. The output will contain instructions on how to grant this notebook access to Earth Engine using your account.

```
import ee  
  
# Trigger the authentication flow.  
ee.Authenticate()  
  
# Initialize the library.  
ee.Initialize()
```

To authorize access needed by Earth Engine, open the following URL in a web browser and follow the instructions. If the web browser does not start automatically, please manually browse the URL below.

```
https://code.earthengine.google.com/client-auth?scopes=https%3A//www.g  
oogleapis.com/auth/earthengine%20https%3A//www.googleapis.com/auth/  
devstorage.full_control&request_id=s8oNZ74PvSe3r8t4YgBuC42foxX5K8lNQx7  
F2yo-hdE&tc=3V6s-jH17ffZm98s2L-
```

k4ektUsUX90Tod7Jzrf_bXn4&cc=_8yK6qjhPPkj_GSsN-SEE-
HZYl7vgbSLN24PkAnayrY

The authorization workflow will generate a code, which you should paste in the box below.

Enter verification code:

4/1AX4XfWi3_Q79RbVoycgPb0gG6zWpEXPrGhUxGtV9oNXnBJeV8_v2tYLUMqQ

Successfully saved authorization token.

Assemble cloud mask components

This section builds an S2 SR collection and defines functions to add cloud and cloud shadow component layers to each image in the collection.

Define collection filter and cloud mask parameters

Define parameters that are used to filter the S2 image collection and determine cloud and cloud shadow identification.

Parameter	Type	Description
AOI	ee.Geometry	Area of interest
START_DATE	string	Image collection start date (inclusive)
END_DATE	string	Image collection end date (exclusive)
CLOUD_FILTER	integer	Maximum image cloud cover percent allowed in image collection
CLD_PRB_THRESH	integer	Cloud probability (%); values greater than are considered cloud
NIR_DRK_THRESH	float	Near-infrared reflectance; values less than are considered potential cloud shadow
CLD_PRJ_DIST	float	Maximum distance (km) to search for cloud shadows from cloud edges
BUFFER	integer	Distance (m) to dilate the edge of cloud-identified objects

The values currently set for AOI, START_DATE, END_DATE, and CLOUD_FILTER are intended to build a collection for a single S2 overpass of a region near Portland, Oregon, USA. When parameterizing and evaluating cloud masks for a new area, it is good practice to identify a

single overpass date and limit the regional extent to minimize processing requirements. If you want to work with a different example, use this [Earth Engine App](#) to identify an image that includes some clouds, then replace the relevant parameter values below with those provided in the app.

```
AOI = ee.Geometry.Point(-0.3780581331738131,39.471157945104885)
START_DATE = '2021-05-05'
END_DATE = '2021-05-06'
CLOUD_FILTER = 60
CLD_PRB_THRESH = 50
NIR_DRK_THRESH = 0.15
CLD_PRJ_DIST = 1
BUFFER = 50
```

Build a Sentinel-2 collection

[Sentinel-2 surface reflectance](#) and [Sentinel-2 cloud probability](#) are two different image collections. Each collection must be filtered similarly (e.g., by date and bounds) and then the two filtered collections must be joined.

Define a function to filter the SR and s2cloudless collections according to area of interest and date parameters, then join them on the `system:index` property. The result is a copy of the SR collection where each image has a new `'s2cloudless'` property whose value is the corresponding s2cloudless image.

```
def get_s2_sr_cld_col(aoi, start_date, end_date):
    # Import and filter S2 SR.
    s2_sr_col = (ee.ImageCollection('COPERNICUS/S2_SR')
                 .filterBounds(aoi)
                 .filterDate(start_date, end_date))

    # Import and filter s2cloudless.
    s2_cloudless_col =
(ee.ImageCollection('COPERNICUS/S2_CLOUD_PROBABILITY')
 .filterBounds(aoi)
 .filterDate(start_date, end_date))

    # Join the filtered s2cloudless collection to the SR collection by
    the 'system:index' property.
    return
ee.ImageCollection(ee.Join.saveFirst('s2cloudless').apply(**{
    'primary': s2_sr_col,
    'secondary': s2_cloudless_col,
    'condition': ee.Filter.equals(**{
        'leftField': 'system:index',
        'rightField': 'system:index'
    })
}))
```

Apply the `get_s2_sr_cld_col` function to build a collection according to the parameters defined above.

```
s2_sr_cld_col_eval = get_s2_sr_cld_col(AOI, START_DATE, END_DATE)
```

Define cloud mask component functions

Cloud components

Define a function to add the s2cloudless probability layer and derived cloud mask as bands to an S2 SR image input.

```
def add_cloud_bands(img):  
    # Get s2cloudless image, subset the probability band.  
    cld_prb = ee.Image(img.get('s2cloudless')).select('probability')  
  
    # Condition s2cloudless by the probability threshold value.  
    is_cloud = cld_prb.gt(CLD_PRB_THRESH).rename('clouds')  
  
    # Add the cloud probability layer and cloud mask as image bands.  
    return img.addBands(ee.Image([cld_prb, is_cloud]))
```

Cloud shadow components

Define a function to add dark pixels, cloud projection, and identified shadows as bands to an S2 SR image input. Note that the image input needs to be the result of the above `add_cloud_bands` function because it relies on knowing which pixels are considered cloudy ('clouds' band).

```
def add_shadow_bands(img):  
    # Identify water pixels from the SCL band.  
    not_water = img.select('SCL').neq(6)  
  
    # Identify dark NIR pixels that are not water (potential cloud  
    shadow pixels).  
    SR_BAND_SCALE = 1e4  
    dark_pixels =  
    img.select('B8').lt(NIR_DRK_THRESH*SR_BAND_SCALE).multiply(not_water).  
    rename('dark_pixels')  
  
    # Determine the direction to project cloud shadow from clouds  
    (assumes UTM projection).  
    shadow_azimuth =  
    ee.Number(90).subtract(ee.Number(img.get('MEAN_SOLAR_AZIMUTH_ANGLE')))  
    ;  
  
    # Project shadows from clouds for the distance specified by the  
    CLD_PRJ_DIST input.  
    cld_proj =  
    (img.select('clouds').directionalDistanceTransform(shadow_azimuth,  
    CLD_PRJ_DIST*10)
```

```

100}) .reproject(**{'crs': img.select(0).projection(), 'scale':
    .select('distance')
    .mask()
    .rename('cloud_transform'))

    # Identify the intersection of dark pixels with cloud shadow
    # projection.
    shadows = cld_proj.multiply(dark_pixels).rename('shadows')

    # Add dark pixels, cloud projection, and identified shadows as
    # image bands.
    return img.addBands(ee.Image([dark_pixels, cld_proj, shadows]))

```

Final cloud-shadow mask

Define a function to assemble all of the cloud and cloud shadow components and produce the final mask.

```

def add_cld_shdw_mask(img):
    # Add cloud component bands.
    img_cloud = add_cloud_bands(img)

    # Add cloud shadow component bands.
    img_cloud_shadow = add_shadow_bands(img_cloud)

    # Combine cloud and shadow mask, set cloud and shadow as value 1,
    # else 0.
    is_cld_shdw =
    img_cloud_shadow.select('clouds').add(img_cloud_shadow.select('shadows
    ')).gt(0)

    # Remove small cloud-shadow patches and dilate remaining pixels by
    # BUFFER input.
    # 20 m scale is for speed, and assumes clouds don't require 10 m
    # precision.
    is_cld_shdw = (is_cld_shdw.focalMin(2).focalMax(BUFFER*2/20)
    .reproject(**{'crs': img.select([0]).projection(), 'scale':
100})
    .rename('cloudmask'))

    # Add the final cloud-shadow mask to the image.
    return img_cloud_shadow.addBands(is_cld_shdw)

```

Visualize and evaluate cloud mask components

This section provides functions for displaying the cloud and cloud shadow components. In most cases, adding all components to images and viewing them is unnecessary. This section is included to illustrate how the cloud/cloud shadow mask is developed and demonstrate

how to test and evaluate various parameters, which is helpful when defining masking variables for an unfamiliar region or time of year.

In applications outside of this tutorial, if you prefer to include only the final cloud/cloud shadow mask along with the original image bands, replace:

```
return img_cloud_shadow.addBands(is_cld_shdw)
```

with

```
return img.addBands(is_cld_shdw)
```

in the above `add_cld_shdw_mask` function.

Define functions to display image and mask component layers.

Folium will be used to display map layers. Import folium and define a method to display Earth Engine image tiles.

```
# Import the folium library.  
import folium
```

```
# Define a method for displaying Earth Engine image tiles to a folium map.
```

```
def add_ee_layer(self, ee_image_object, vis_params, name, show=True,  
opacity=1, min_zoom=0):  
    map_id_dict = ee.Image(ee_image_object).getMapId(vis_params)  
    folium.raster_layers.TileLayer(  
        tiles=map_id_dict['tile_fetcher'].url_format,  
        attr='Map Data &copy; <a  
href="https://earthengine.google.com/">Google Earth Engine</a>',  
        name=name,  
        show=show,  
        opacity=opacity,  
        min_zoom=min_zoom,  
        overlay=True,  
        control=True  
    ).add_to(self)
```

```
# Add the Earth Engine layer method to folium.  
folium.Map.add_ee_layer = add_ee_layer
```

Define a function to display all of the cloud and cloud shadow components to an interactive Folium map. The input is an image collection where each image is the result of the `add_cld_shdw_mask` function defined previously.

```
def display_cloud_layers(col):  
    # Mosaic the image collection.  
    img = col.mosaic()  
  
    # Subset layers and prepare them for display.
```

```

clouds = img.select('clouds').selfMask()
shadows = img.select('shadows').selfMask()
dark_pixels = img.select('dark_pixels').selfMask()
probability = img.select('probability')
cloudmask = img.select('cloudmask').selfMask()
cloud_transform = img.select('cloud_transform')

# Create a folium map object.
center = AOI.centroid(10).coordinates().reverse().getInfo()
m = folium.Map(location=center, zoom_start=12)

# Add layers to the folium map.
m.add_ee_layer(img,
                {'bands': ['B4', 'B3', 'B2'], 'min': 0, 'max':
2500, 'gamma': 1.1},
                'S2 image', True, 1, 9)
m.add_ee_layer(probability,
                {'min': 0, 'max': 100},
                'probability (cloud)', False, 1, 9)
m.add_ee_layer(clouds,
                {'palette': 'e056fd'},
                'clouds', False, 1, 9)
m.add_ee_layer(cloud_transform,
                {'min': 0, 'max': 1, 'palette': ['white',
'black']},
                'cloud_transform', False, 1, 9)
m.add_ee_layer(dark_pixels,
                {'palette': 'orange'},
                'dark_pixels', False, 1, 9)
m.add_ee_layer(shadows, {'palette': 'yellow'},
                'shadows', False, 1, 9)
m.add_ee_layer(cloudmask, {'palette': 'orange'},
                'cloudmask', True, 0.5, 9)

# Add a layer control panel to the map.
m.add_child(folium.LayerControl())

# Display the map.
display(m)

```

Display mask component layers

Map the `add_cld_shdw_mask` function over the collection to add mask component bands to each image, then display the results.

Give the system some time to render everything, it should take less than a minute.

```

s2_sr_cld_col_eval_disp = s2_sr_cld_col_eval.map(add_cld_shdw_mask)

display_cloud_layers(s2_sr_cld_col_eval_disp)

```

```
<folium.folium.Map at 0x7f97d0589d90>
```

Evaluate mask component layers

In the above map, use the layer control panel in the upper right corner to toggle layers on and off; layer names are the same as band names, for easy code referral. Note that the layers have a minimum zoom level of 9 to avoid resource issues that can occur when visualizing layers that depend on the `ee.Image.reproject` function (used during cloud shadow project and mask dilation).

Try changing the above `CLD_PRB_THRESH`, `NIR_DRK_THRESH`, `CLD_PRJ_DIST`, and `BUFFER` input variables and rerunning the previous cell to see how the results change. Find a good set of values for a given overpass and then try the procedure with a new overpass with different cloud conditions (this [S2 SR image browser app](#) is handy for quickly identifying images and determining image collection filter criteria). Try to identify a set of parameter values that balances cloud/cloud shadow commission and omission error for a range of cloud types. In the next section, we'll use the values to actually apply the mask to generate a cloud-free composite for 2020.

Apply cloud and cloud shadow mask

In this section we'll generate a cloud-free composite for the same region as above that represents mean reflectance for July and August, 2020.

Define collection filter and cloud mask parameters

We'll redefine the parameters to be a little more aggressive, i.e. decrease the cloud probability threshold, increase the cloud projection distance, and increase the buffer. These changes will increase cloud commission error (mask out some clear pixels), but since we will be compositing images from three months, there should be plenty of observations to complete the mosaic.

```
AOI = ee.Geometry.Point(-0.3780581331738131, 39.471157945104885)
START_DATE = '2021-05-05'
END_DATE = '2021-05-06'
CLOUD_FILTER = 60
CLD_PRB_THRESH = 50
NIR_DRK_THRESH = 0.15
CLD_PRJ_DIST = 1
BUFFER = 50
```

Build a Sentinel-2 collection

Reassemble the S2-cloudless collection since the collection filter parameters have changed.

```
s2_sr_cld_col = get_s2_sr_cld_col(AOI, START_DATE, END_DATE)
```

Define cloud mask application function

Define a function to apply the cloud mask to each image in the collection.

```

def apply_cld_shdw_mask(img):
    # Subset the cloudmask band and invert it so clouds/shadow are 0,
    # else 1.
    not_cld_shdw = img.select('cloudmask').Not()

    # Subset reflectance bands and update their masks, return the
    # result.
    return img.select('B.*').updateMask(not_cld_shdw)

```

Process the collection

Add cloud and cloud shadow component bands to each image and then apply the mask to each image. Reduce the collection by median (in your application, you might consider using medoid reduction to build a composite from actual data values, instead of per-band statistics).

```

s2_sr_median = (s2_sr_cld_col.map(add_cld_shdw_mask)
                .map(apply_cld_shdw_mask)
                .median())

```

Display the cloud-free composite

Display the results. Be patient while the map renders, it may take a minute; `ee.Image.reproject` is forcing computations to happen at 100 and 20 m scales (i.e. it is not relying on appropriate pyramid level [scales for analysis](#)). The issues with `ee.Image.reproject` being resource-intensive in this case are mostly confined to interactive map viewing. Batch image [exports](#) and table reduction exports where the scale parameter is set to typical Sentinel-2 scales (10-60 m) are less affected.

```

# Create a folium map object.
center = AOI.centroid(10).coordinates().reverse().getInfo()
m = folium.Map(location=center, zoom_start=12)

# Add layers to the folium map.
m.add_ee_layer(s2_sr_median,
               {'bands': ['B4', 'B3', 'B2'], 'min': 0, 'max': 2500,
                'gamma': 1.1},
               'S2 cloud-free mosaic', True, 1, 9)

# Add a layer control panel to the map.
m.add_child(folium.LayerControl())

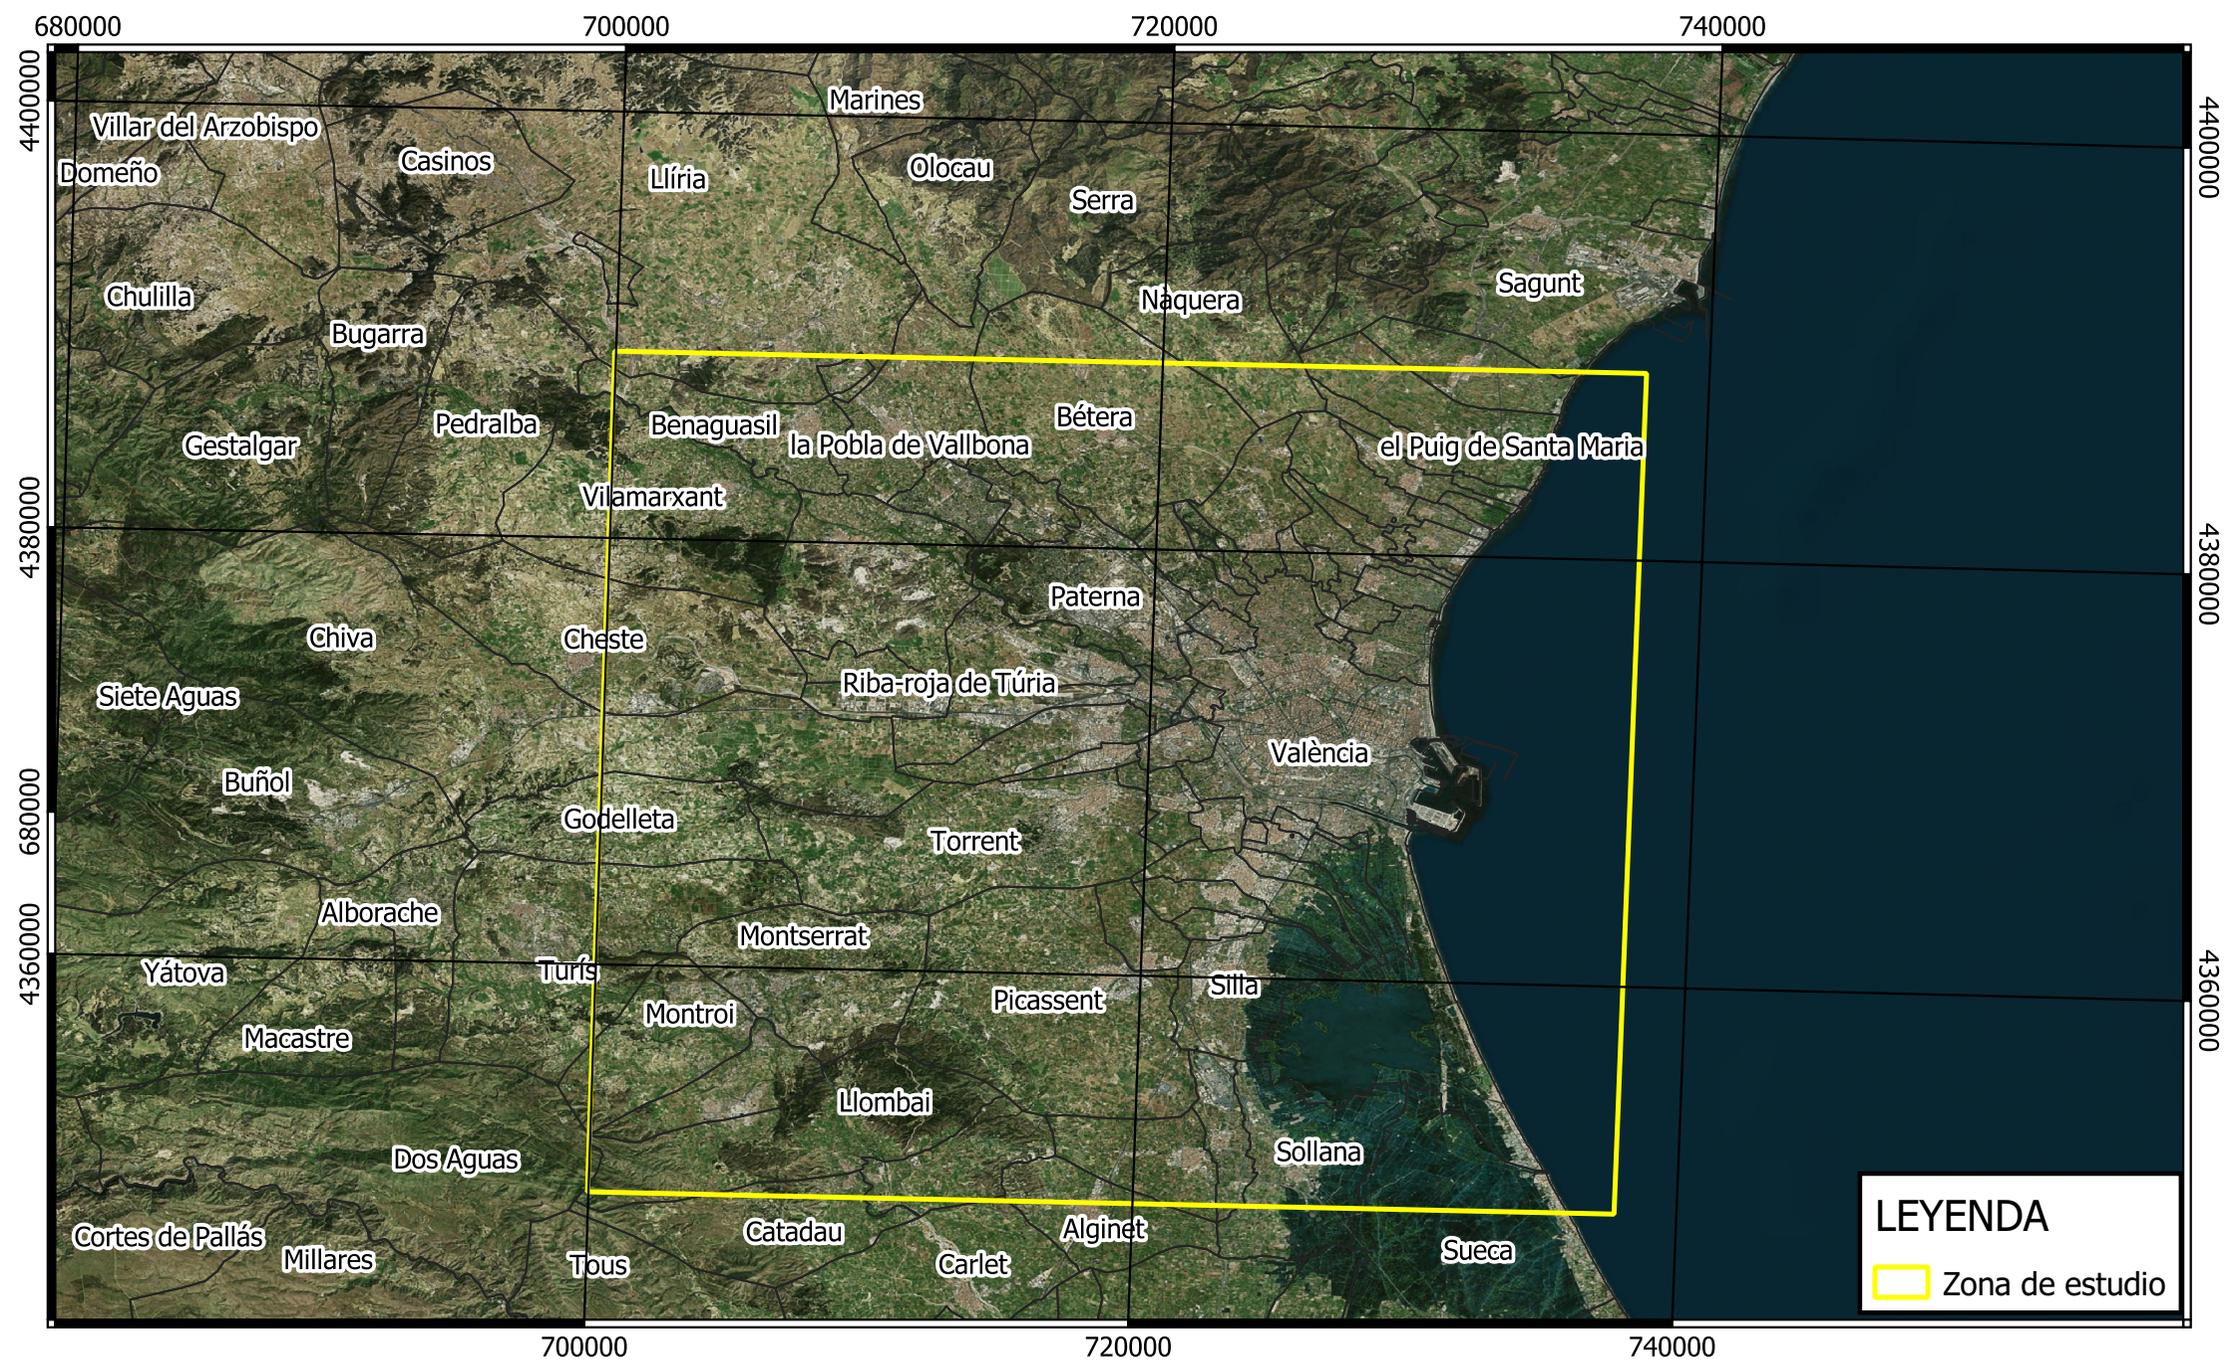
# Display the map.
display(m)

<folium.folium.Map at 0x7f97cfedbed0>

```

Hopefully you now have a good sense for Sentinel-2 cloud masking in the cloud 😊 with Earth Engine.

11. CARTOGRAFÍA



LEYENDA

 Zona de estudio

<p>TÍTULO:</p> <p>MAPA DE LA ZONA DE ESTUDIO</p>	<p>Nº PLANO:</p> <p>1</p>	<p>SRC:</p> <p>ETRS 89 UTM ZONA 30</p>	<p>ESCALA:</p> <p>1:200.000</p> 	 <p>ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA GEODÉSICA CARTOGRÁFICA Y TOPOGRÁFICA UNIVERSITAT POLITÈCNICA DE VALÈNCIA</p>
---	----------------------------------	---	--	--

720000

730000

740000

4380000

4380000

4370000

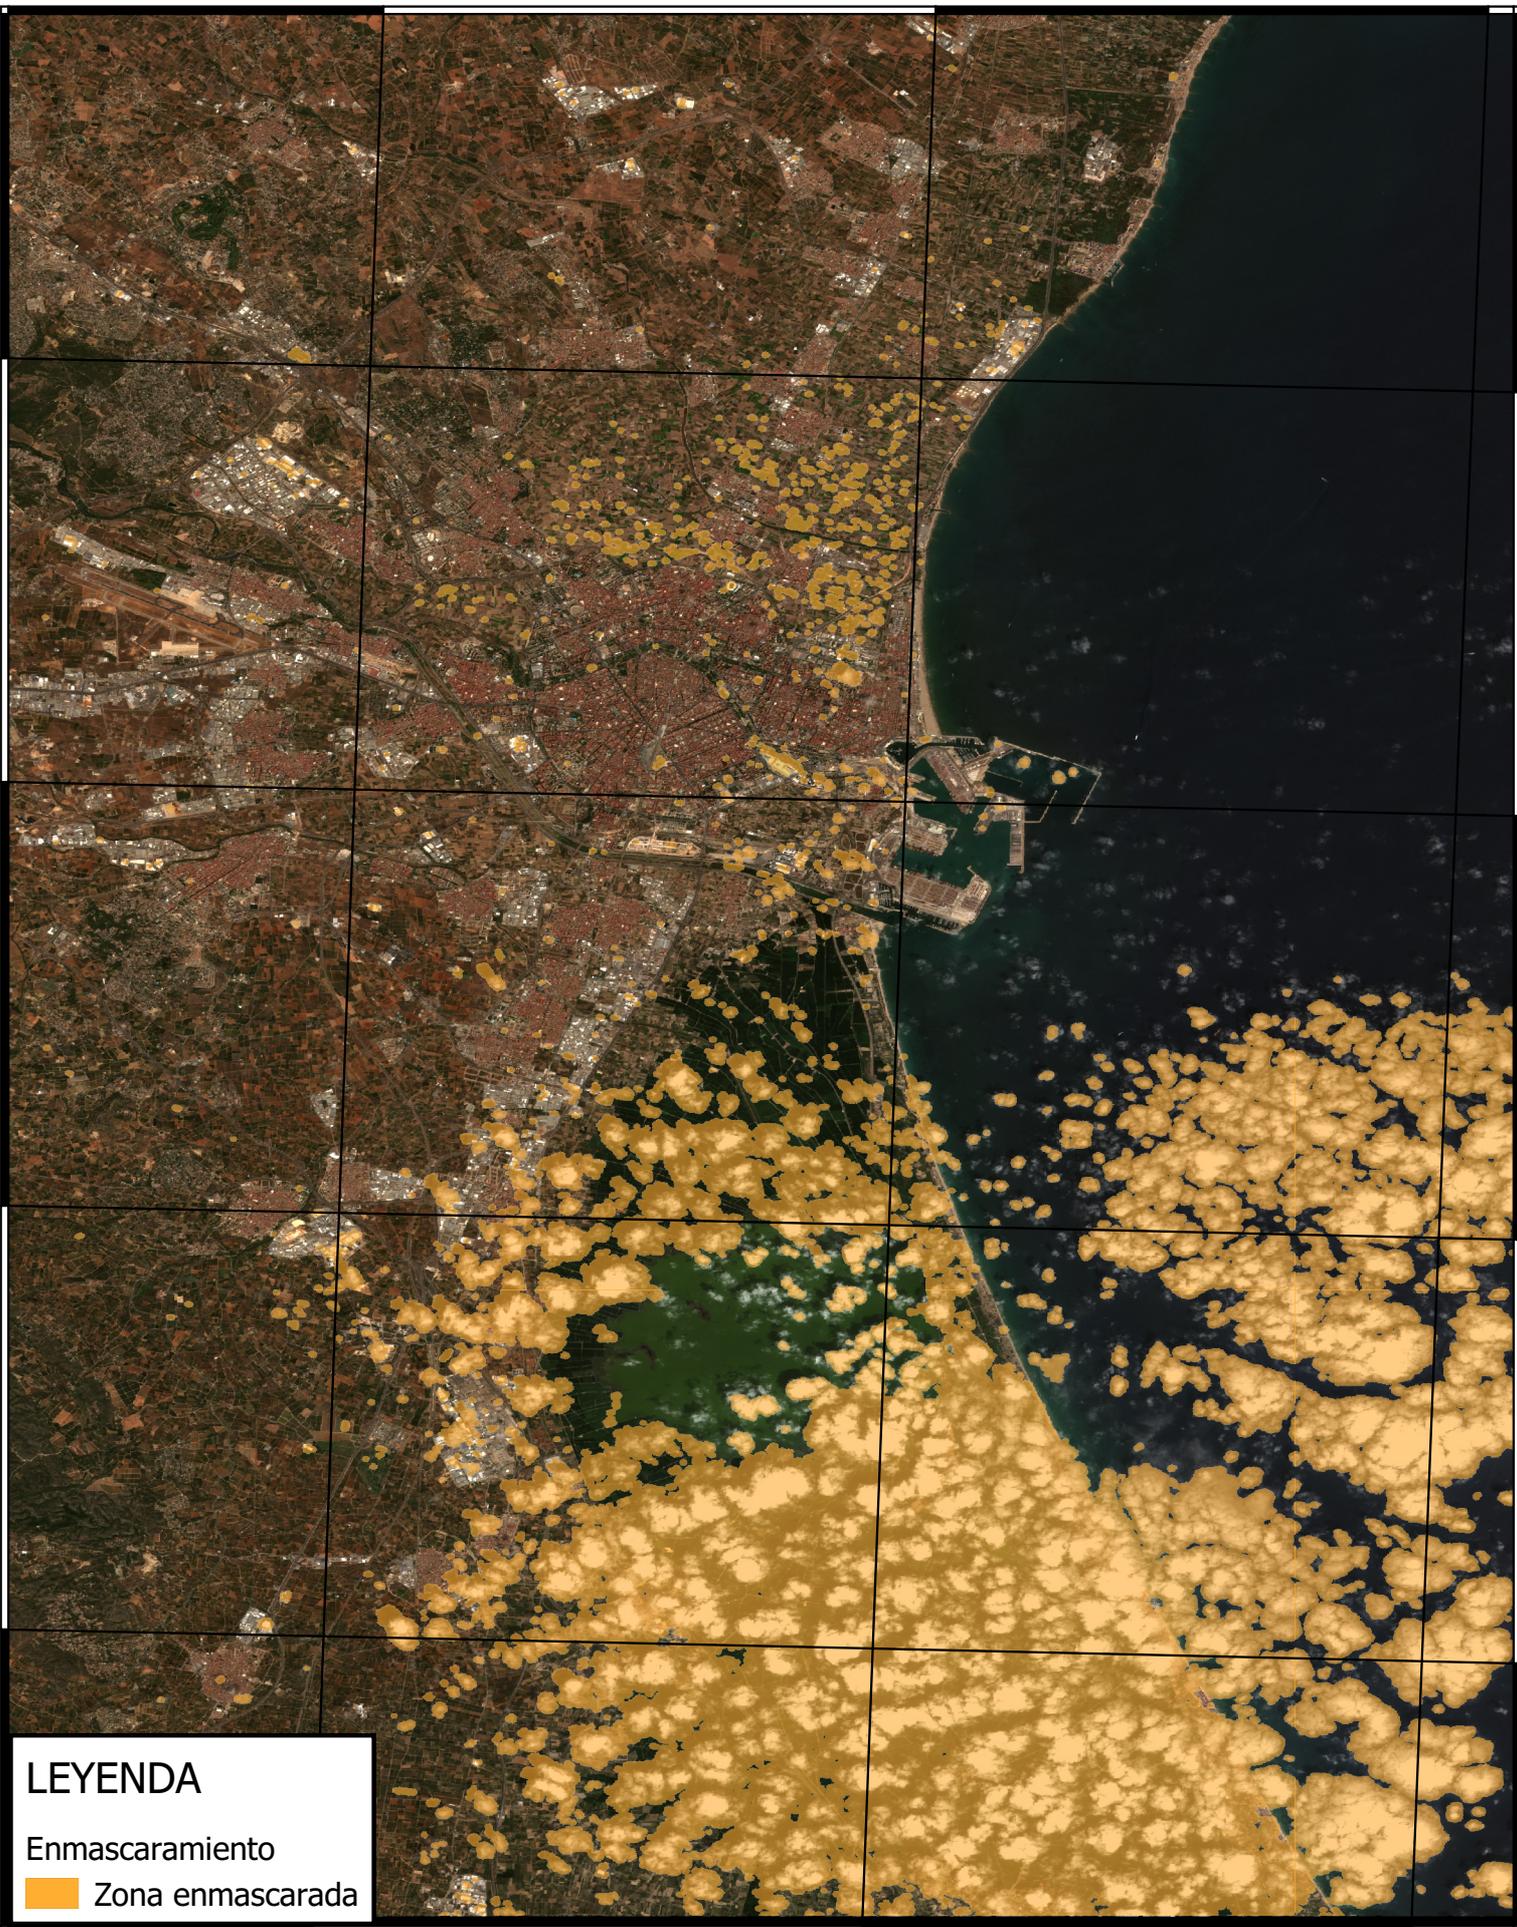
4370000

4360000

4360000

4350000

4350000



LEYENDA

Enmascaramiento
 Zona enmascarada

720000

730000

740000

TÍTULO:
 MAPA EJEMPLO 1
 ENMASCARAMIENTO DE NUBES

Nº:
 2

SRC:
 ETRS 89
 UTM ZONA 30

ESCALA:
 0 1.5 3 4.5 km

 1:100.000



720000

730000

740000

4380000

4380000

4370000

4370000

4360000

4360000

4350000

4350000



LEYENDA

- Enmascaramiento
-  Zonas de nubes

720000

730000

740000

TÍTULO:

MAPA EJEMPLO 2
ENMASCARAMIENTO DE NUBES

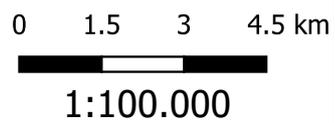
Nº:

3

SRC:

ETRS 89
UTM ZONA 30

ESCALA:



ESCUELA TÉCNICA SUPERIOR
DE INGENIERÍA GEODÉSICA
CARTOGRÁFICA Y TOPOGRÁFICA
UNIVERSITAT POLITÈCNICA DE VALÈNCIA

700000

710000

720000

730000

4380000

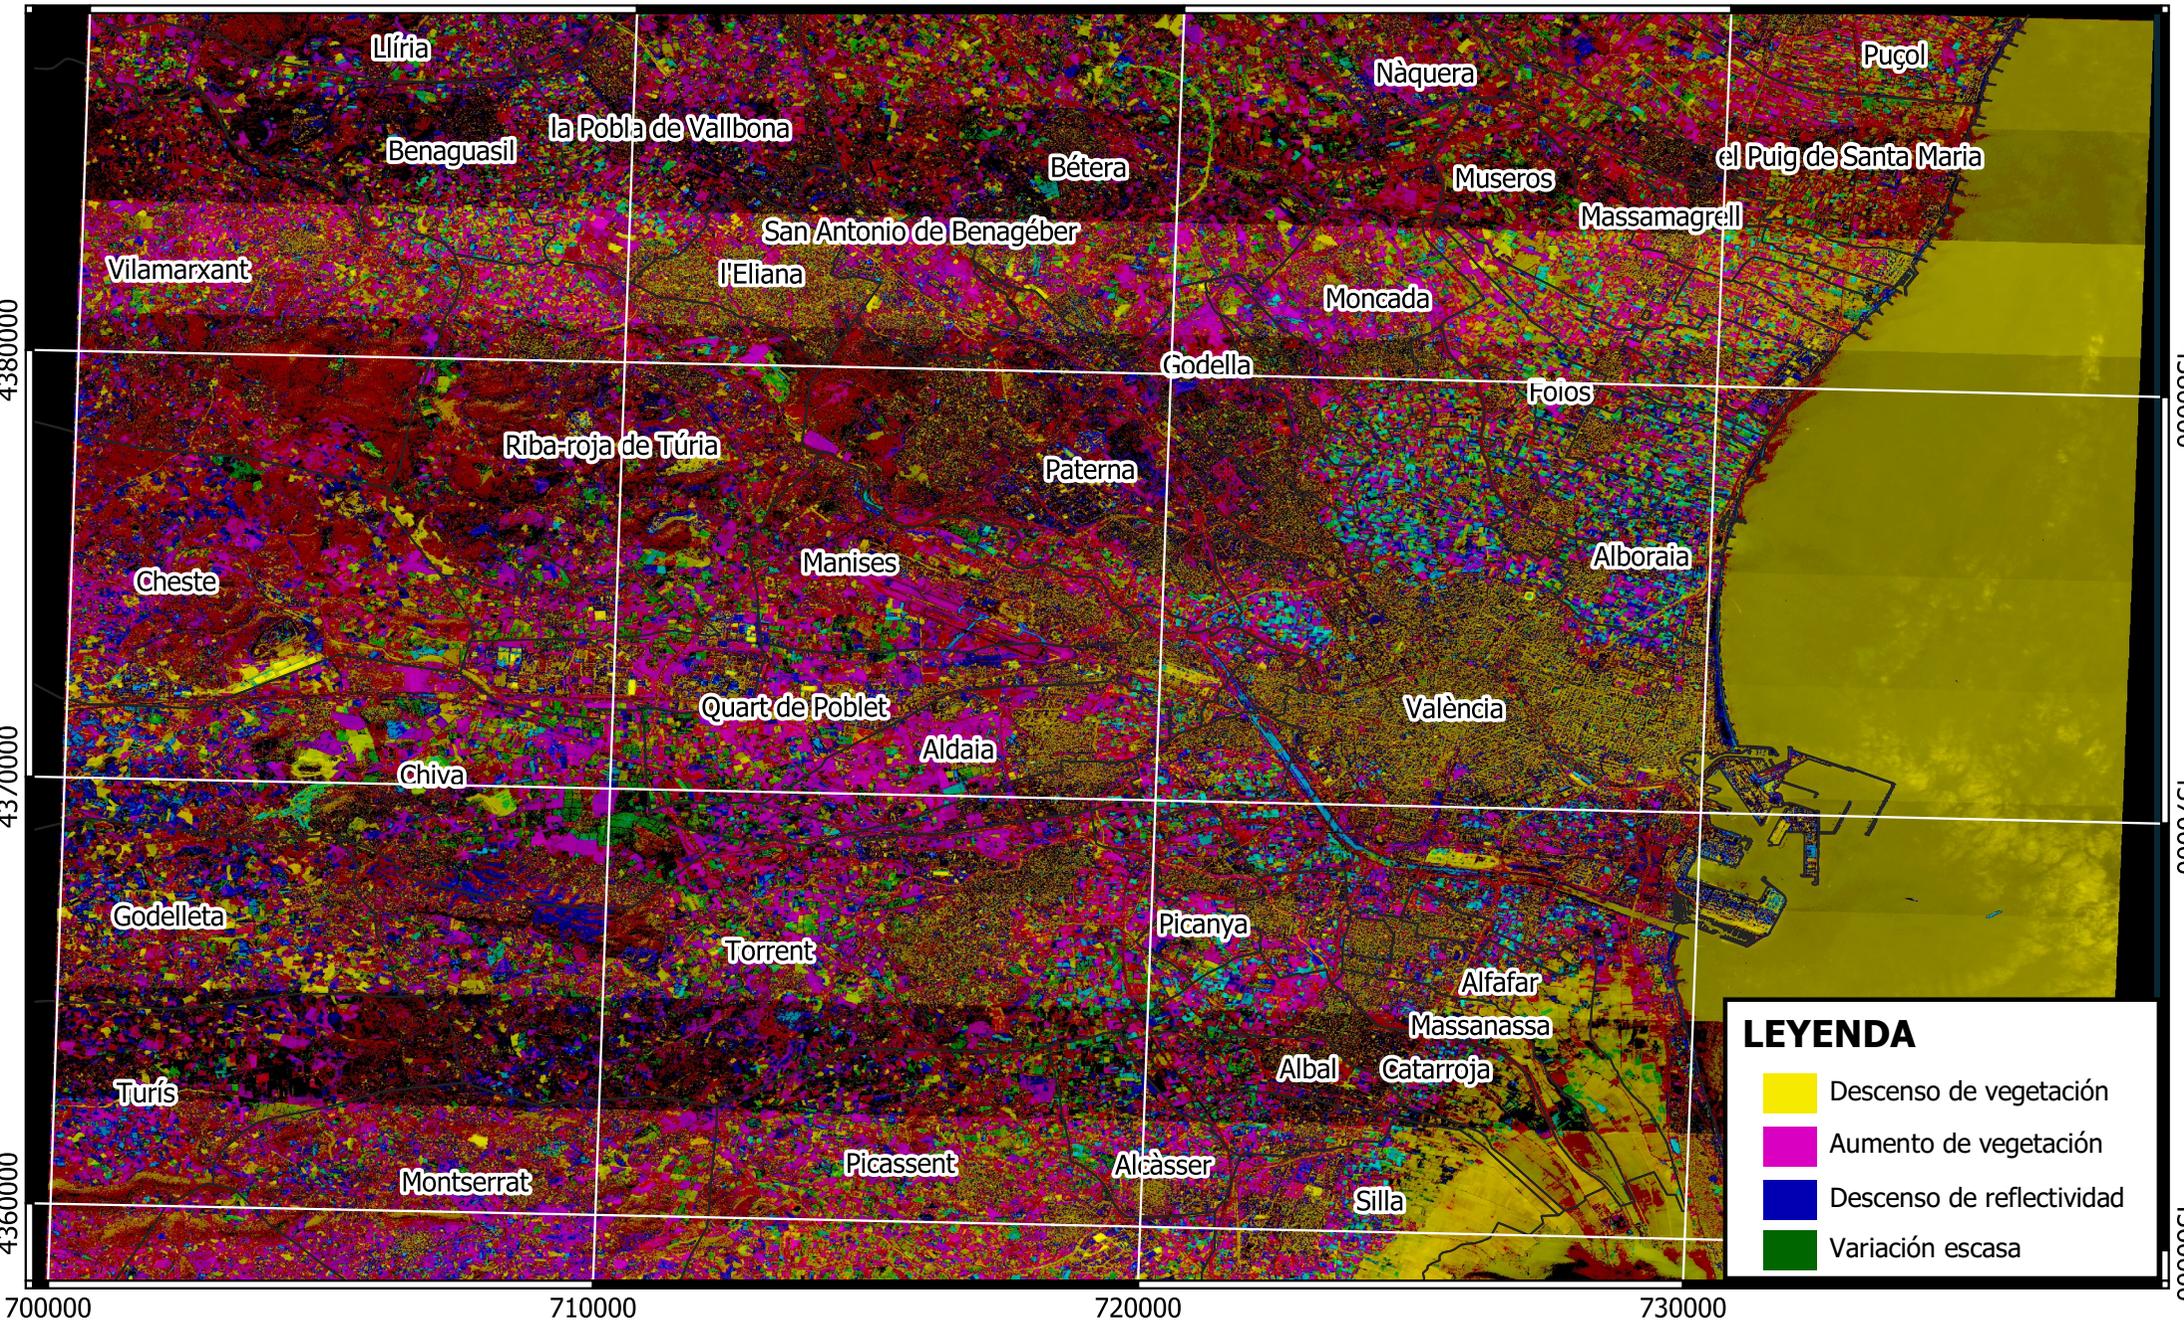
4380000

4370000

4370000

4360000

4360000



LEYENDA

- Descenso de vegetación
- Aumento de vegetación
- Descenso de reflectividad
- Variación escasa

TÍTULO:
 MAPA RGB DE CAMBIOS DE LA
 ZONA DE ESTUDIO

Nº PLANO:
 4

SRC:
 ETRS 89
 UTM ZONA 30

ESCALA:
 1:100.000



700000

710000

720000

730000

4380000

4380000

4370000

4370000

4360000

4360000

700000

710000

720000

730000

Llíria

Benaguasil

la Pobla de Vallbona

Bétera

Nàquera

Puçol

el Puig de Santa Maria

Vilamarxant

San Antonio de Benagéber

Museros

Massamagrell

l'Eliana

Moncada

Godella

Foios

Riba-roja de Túria

Paterna

Cheste

Manises

Alboraià

Chiva

Quart de Poblet

Aldaia

València

Godolleta

Torrent

Picanya

Alfajar

Turís

Montserrat

Picassent

Alcàsser

Massanassa

Albal

Catarroja

Silla

LEYENDA

Mascara

 Zona invariante

TÍTULO:

MAPA DE ZONAS INVARIANTES

Nº PLANO:

5

SRC:

ETRS 89
UTM ZONA 30

ESCALA:

1:100.000

0 1 2 3 4 5 km



ESCUELA TÉCNICA SUPERIOR
DE INGENIERÍA GEODÉSICA
CARTOGRÁFICA Y TOPOGRÁFICA
UNIVERSITAT POLITÈCNICA DE VALÈNCIA

700000

710000

720000

730000

4380000

4380000

4370000

4370000

4360000

4360000

700000

710000

720000

730000

Llíria

Benaguasil

la Pobla de Vallbona

Bétera

Nàquera

Puçol

Vilamarxant

San Antonio de Benagéber

l'Elia

Museros

Massamagrell

el Puig de Santa Maria

Moncada

Godella

Foios

Riba-roja de Túria

Paterna

Cheste

Manises

Alborai

Quart de Poblet

Aldaia

València

Chiva

Godolleta

Torrent

Picanya

Alfajar

Turís

Albal

Massanassa

Catarroja

Montserrat

Picassent

Alcàsser

Silla

LEYENDA

- Descenso de vegetación
- Aumento de vegetación
- Descenso de reflectividad
- Variación escasa
- Zona Invariante

TÍTULO:

MAPA DE ZONAS INVARIANTES

Nº PLANO:

6

SRC:

ETRS 89
UTM ZONA 30

ESCALA:

1:100.000

0 1 2 3 4 5 km



ESCUELA TÉCNICA SUPERIOR
DE INGENIERÍA GEODÉSICA
CARTOGRÁFICA Y TOPOGRÁFICA
UNIVERSITAT POLITÈCNICA DE VALÈNCIA