



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA



ESCUELA TÉCNICA SUPERIOR  
DE INGENIERÍA GEODÉSICA  
CARTOGRÁFICA Y TOPOGRÁFICA

**TRABAJO FIN DE GRADO**

# **GRADO EN INGENIERÍA GEOMÁTICA Y TOPOGRAFÍA**

**Análisis de la biomasa forestal mediante imágenes de satélite.**

Teledetección aplicada a la gestión forestal

Valencia, Julio 2019

**AUTOR: SILVIA APARISI NAVARRO**

[silapna@cam.upv.es](mailto:silapna@cam.upv.es)

**TUTOR: ELOÍNA PEREGRINA COLL ALIAGA**

[ecoll@cgf.upv.es](mailto:ecoll@cgf.upv.es)

**TUTOR EXPERIMENTAL: DAVID VINUÉ VISÚS**

[davivi1@upv.es](mailto:davivi1@upv.es)





## 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

El 62% de las masas arboladas de la Comunidad Valenciana tienen como especie dominante el *Pinus halepensis* Mill. De todos es sabido que los bosques son un gran sumidero de carbono, pero a su vez pueden ser una gran fuente de emisiones de CO<sub>2</sub>

En una época donde el **cambio climático** es uno de los grandes problemas actuales, el conocimiento de las cantidades de **biomasa** y su distribución puede ser una herramienta muy útil en la gestión forestal, que, si es manejada con conocimiento puede ayudar a combatir éste gran problema.

En este proyecto se ha generado un **mapa de biomasa para zonas de *Pinus halepensis* de la Comunidad Valenciana**.

Se ha realizado a partir de:

- datos de un inventario forestal propio
- datos LiDAR -PNOA
- imágenes Sentinel-2

Que conformaran la base de datos de entrenamiento de un proceso de **aprendizaje automático** (*machine learning*) para estimar el valor de biomasa, para después realizar el mapa citado anteriormente.

Y como tan importante es conocer la biomasa de los bosques, como el carbón retenido en los mismos, se ha elaborado a su vez el mapa de **stock de carbono**.

Estos mapas además de una herramienta visual para la gestión, pueden ser utilizados para extracción de datos muy interesantes, como la **cuantificación del CO<sub>2</sub>** retenido en los montes de *Pinus Halepensis*, dato calculado en este proyecto.

Los mapas obtenidos se podrán integrar en un Sistema de Información Geográfica y combinarse con otras capas cartográficas, para, por ejemplo evaluar los riesgos de incendio.

La replicación de éste método en otra época (actual o pasada) permitirá el estudio de la evolución de la biomasa en las masas de *Pinus Halepensis*

Esta metodología es replicable a otros montes actualizando las ecuaciones alométricas para cada especie forestal.

## Contenido

1. INTRODUCCIÓN.....	11
1.1 EL CAMBIO CLIMÁTICO. ....	11
1.2 LA GESTIÓN FORESTAL.....	11
1.3 LA COMUNIDAD VALENCIANA.....	12
1.4 LA TELEDETECCIÓN Y LA BIOMASA .....	12
2. ANTECEDENTES Y JUSTIFICACIÓN.....	16
3. OBJETIVOS.....	17
4. MATERIALES .....	18
4.1 INVENTARIO FORESTAL .....	18
4.2 IMÁGENES SATELITALES SENTINEL-2.....	18
4.3 CAPAS VECTORIALES .....	20
4.4 LIDAR-PNOA .....	21
5. METODOLOGIA .....	22
5.1 GENERACIÓN DE LA BASE DE DATOS DEL ENTRENAMIENTO.....	22
5.1.1 DATOS DE CAMPO .....	22
5.1.2 DATOS LIDAR .....	25
5.1.3 DATOS SENTINEL -2.....	25
5.2 ENTRENAMIENTO Y VALIDACIÓN DE LOS PROCESOS GAUSSIANOS.....	26
5.3 APLICACIÓN DE LAS MÁQUINAS ENTRENADAS PARA LA GENERACIÓN DE IMÁGENES DE BIOMASA.....	27
5.4 GENERACIÓN MAPAS DE BIOMASADE LA COMUNIDAD VALENCIANA	28
5.5 GENERACIÓN DEL MAPA DE STOCK DE CARBONO .....	30
5.5.1 CONVERSIÓN DE VALORES DE t/ha a t/pixel .....	30
5.5.2 CALCULO DE BIOMASAEN LA ZONA DE <i>Pinus Halepensis</i> .....	30
5.5.3 CONVERSION DE BIOMASAA CARBONO.....	30
5.6 CUANTIFICACIÓN DE CO <sub>2</sub> RETENIDO Y RELACIÓN ENTRE VARIABLES ....	31
6. RESULTADOS Y DISCUSIÓN .....	33
6.1 RESULTADOS .....	33
6.2 DISCUSIÓN .....	36
7. CARTOGRAFIA GENERADA .....	38
8. CONCLUSIONES.....	39
8.1 Perspectivas futuras .....	39



9. PRESUPUESTO .....	40
10. BIBLIOGRAFIA .....	44
ANEJOS .....	47
ANEJO 1. Tabla Resumen Inventario de campo .....	48
ANEJO 2. Base de datos de campo .....	53
ANEJO 3. Procesado Información LiDAR .....	55
ANEJO 4. Tabla estadísticos LiDAR .....	58
ANEJO 5. Procesado Sentinel 2 .....	66
ANEJO 6. Códigos IDL empleados.....	71
ANEJO 7. Base de Datos .....	83
ANEJO 8. Métodos de aprendizaje automático .....	94
ANEJO 9. Máquinas entrenadas .....	102
ANEJO 10. Códigos Matlab .....	108
ANEJO 11. Segmentación SIG .....	117
ANEJO 12. Comunicación con la Dirección General de Desarrollo rural Innovación y Política Forestal .....	120
ANEJO 13. Clasificación climática de Köppen-Geiger.....	122
ANEJO 14. Herramienta cálculo de Biomasa .....	124



## ÍNDICE DE TABLAS

Tabla 1. <i>Pinus Halepensis</i> en la comunidad Valenciana. Fuente propia a partir del Mapa forestal Nacional .....	12
Tabla 2. Estudios previos. Fuente: Galidaki et al (2017) .....	13
Tabla 3. Aprendizaje automático para cálculo de la biomasa. Fuente: Ali et al (2015) .....	14
Tabla 4. Tipos de productos Sentinel 2. Fuente: <a href="https://earth.esa.int/web/Sentinel/user-guides/Sentinel-2-msi/product-types">https://earth.esa.int/web/Sentinel/user-guides/Sentinel-2-msi/product-types</a> .....	18
Tabla 5. Bandas de 10 metros de resolución espacial. Fuente: <a href="https://earth.esa.int/web/Sentinel/user-guides/Sentinel-2-msi/resolutions/radiometric">https://earth.esa.int/web/Sentinel/user-guides/Sentinel-2-msi/resolutions/radiometric</a> .	18
Tabla 6. . Bandas de 20 metros de resolución espacial Fuente: <a href="https://earth.esa.int/web/Sentinel/user-guides/Sentinel-2-msi/resolutions/radiometric">https://earth.esa.int/web/Sentinel/user-guides/Sentinel-2-msi/resolutions/radiometric</a> .	19
Tabla 7. Bandas de 60 metros de resolución espacial. Fuente: <a href="https://earth.esa.int/web/Sentinel/user-guides/Sentinel-2-msi/resolutions/radiometric">https://earth.esa.int/web/Sentinel/user-guides/Sentinel-2-msi/resolutions/radiometric</a> .	19
Tabla 8. Imágenes empleadas en el proyecto.....	20
Tabla 9. Capas empleadas en el proyecto .....	20
Tabla 10. Ecuaciones alométricas para el cálculo de biomasa según Ruiz-Peinado et al (2011) .....	24
Tabla 11. Clasificación de las estructuras forestales para la base de datos de entrenamiento .....	24
Tabla 12. Reflectividades imágenes Sentinel-2.....	26
Tabla 13. Combinaciones testeadas en los Procesos Gaussianos .....	27
Tabla 14. Biomasa por fracciones arbóreas.....	31
Tabla 15. Píxeles de la imagen según la resolución espacial. ....	68
Tabla 16. Parámetros Kernel .....	105
Tabla 17. Resumen combinaciones .....	107

## ÍNDICE DE FIGURAS

Figura 1. Comparativa métodos machine Learning para variables biofísicas. Fuente: Fuster.B (2017) .....	15
Figura 2. Zonas UTM Sentinel-2 Comunidad Valenciana. Fuente: propia .....	19
Figura 3. Estructuras forestales. Fuente: Atlas Forestal de Castilla y León.....	22
Figura 4. Situación parcelas de estudio .....	23
Figura 5. Cadena de procesado de datos LiDAR-PNOA .....	25
Figura 6. Imagen Sentinel-2, Visualización en color verdadero .....	28
Figura 7. Resultado código Matlab para generación de imágenes de Biomasa .....	28
Figura 8. Procesado para la generación de mapas de Biomasa.....	29
Figura 9. Esquema hectárea-píxel.....	30
Figura 10. Mapa base para el cálculo de CO <sub>2</sub> retenido.....	30
Figura 11. Esquema Relación entre BiomasaCarbono y CO <sub>2</sub> .....	32
Figura 12. Resultados gráficos de la validación de los procesos Gaussianos para latizal- fustal y monte bravo , de las bandas 8A y NDVI .....	34
Figura 13. Validación conjunta del modelo para las bandas NDVI + 8A.....	34
Figura 14. LasMerge de LASTools .....	56
Figura 15. Recorte de la nube de puntos .....	56
Figura 16. Normalización de la nube de puntos.....	57
Figura 17. Estructura de datos de imágenes Sentinel 2A en nivel L1C .....	67
Figura 18. Procedimientos para el procesado de Sentinel-2. Fuente: David Vinué Visús68	
Figura 19. Predicción variable.....	95
Figura 20. Funcionamiento de una neurona. Fuente: DOTcsv .....	97
Figura 21. Red neuronal. DOTcsv .....	98
Figura 22. Fórmulas capas sucesivas.....	98
Figura 23. Distribución Gaussiana 2 variables. Fuente: Galipedia.....	99
Figura 24. Distribución Gaussiana multivariable.....	99
Figura 25. Formulas procesos Gaussianos.....	100
Figura 26. Transformación a partir de kernel. <a href="http://www.eric-kim.net/eric-kim-net/posts/1/imgs/data_2d_to_3d.png">http://www.eric-kim.net/eric-kim- net/posts/1/imgs/data_2d_to_3d.png</a> .....	101
Figura 27. SENTINEL + LiDAR.....	103
Figura 28. SENTINEL + LIDAR sin suelo .....	103
Figura 29. Sentinel con y sin suelo .....	103
Figura 30. LiDAR .....	104
Figura 31. LiDAR sin suelo.....	104
Figura 32.NDVI+KURT+P60 .....	104
Figura 33. Mix .....	105
Figura 34. NDVI 8A.....	106
Figura 35. NDVI 8A P90 .....	106
Figura 36. Ejemplo Extract by mask .....	118
Figura 37. Resultado mapa Biomasaen zonas de Pinus halepensis .....	119
Figura 38. Mosaico de Imágenes Sentinel (izquierda) Resultado de la unión y recorte de las imágenes del mosaico (derecha) .....	119

## GLOSARIO Y ACRÓNIMOS

<b>BBDD</b>	Base de datos.
<b>BOA</b>	Bottom of Atmosphere
<b>Dasometría</b>	Parte de la dasonomía, que se ocupa de las mediciones de árboles y masas forestales, así como del estudio de las leyes métricas que rigen su evolución.
<b>Dasonomía</b>	Conjunto de disciplinas que estudian los bosques respecto de su formación, manejo, reproducción y aprovechamiento.
<b>Dendrometría</b>	Parte de la dasometría que trata de la medida de las dimensiones del árbol individualmente, del estudio de su forma y de la determinación de su volumen.
<b>ESA</b>	European Space Agency
<b>ETM</b>	Enhanced Thematic Mapper
<b>Fustal</b>	Clase natural de edad que se aplica cuando el diámetro normal medio supera los 20 cm. Se puede distinguir a su vez fustal bajo (20 - 35 cm) y fustal alto (35 - 50 cm).
<b>IFN3</b>	Tercer Inventario Forestal Nacional español (1997-2007)
<b>IPCC</b>	Grupo Intergubernamental de Expertos sobre el Cambio Climático.
<b>Latizal</b>	Se dice de la edad o del conjunto de árboles jóvenes y rectos, de unos diez a veinte centímetros de diámetro (a veces se admite hasta 30 cm).
<b>MFN</b>	Mapa Forestal Nacional
<b>Monte bravo</b>	Clase natural de edad del arbolado que comienza cuando se inicia la tangencia de copas o bien se alcanza una altura de 130 cm y se mantiene hasta que se inicia la poda natural y la edad de latizal.
<b>MSI</b>	MultiSpectral Instrument
<b>NDVI</b>	Normalized Difference Vegetation Index
<b>OLS</b>	Ordinary Least Squares
<b>R<sup>2</sup></b>	Coefficiente de determinación
<b>RMSE</b>	Root Mean Square Error
<b>SEN2COR</b>	Procesador para la generación de los niveles L2A en Sentinel-2A
<b>SNAP</b>	Sentinel Application Platform
<b>SWIR</b>	Short Wave Infra-Red
<b>TOA</b>	Top of Atmosphere.



## 1. INTRODUCCIÓN

### 1.1 EL CAMBIO CLIMÁTICO.

“Se llama **cambio climático** a la variación global del clima de la Tierra. Esta variación se debe a causas naturales y a la acción del hombre y se produce sobre todos los parámetros climáticos: temperatura, precipitaciones, nubosidad, etc., a muy diversas escalas de tiempo.”

Ésta es la definición que podemos encontrar en la página web del ministerio para la transición ecológica sobre qué entender por cambio climático.

Según el Informe de Síntesis del Quinto Informe de Evaluación del IPCC (Grupo intergubernamental de Expertos sobre Cambio Climático) “*para limitar realmente los riesgos del cambio climático, es necesario reducir de forma sustancial y sostenida las emisiones de **gases de efecto invernadero***” (IPCC 2018).

Los principales gases de efecto invernadero, según el Protocolo de Kioto son:

- Dióxido de carbono
- Metano
- Óxido nitroso

Sólo estos 3 gases explican el 74% del efecto global del calentamiento mundial, En un (50, 18 y 6 por ciento respectivamente).

El dióxido de Carbono se puede encontrar principalmente en:

1. **La atmósfera.** La presencia de dióxido de carbono en la atmósfera entre otros gases es precisamente la causa del calentamiento global, que a su vez produce el cambio climático.
2. **El subsuelo** como parte de combustibles fósiles.
3. **Los océanos.** Considerados los principales sumideros de carbono naturales absorbiendo aproximadamente el 50% de CO<sub>2</sub> emitido a la atmósfera.
4. **Los bosques.** Otro de los sumideros de carbono naturales, los árboles y plantas mediante la fotosíntesis absorben CO<sub>2</sub>, y devuelven oxígeno a la atmósfera.

De las cuatro zonas donde se puede encontrar, la más sencilla de gestionar son los bosques.

### 1.2 LA GESTIÓN FORESTAL

¿Por qué interesa gestionar los bosques?

Porque los bosques son uno de los mayores reservorios de carbono del planeta, pero también pueden llegar a ser una importante fuente de emisiones, en caso de incendio forestal.

La biomasa forestal es la cantidad de materia viva presente en los bosques. Cuantificarla es de suma importancia ya que está directamente relacionada con el stock y secuestro de carbono.

Cuanta más biomasa más stock de carbono, sin embargo la disposición de esa

biomasa en el espacio juega un papel crucial en la dispersión de un incendio, ya que una biomasa no gestionada aumenta las probabilidades de difusión de un incendio y por el contrario, una biomasa gestionada y bien repartida, minimiza estas probabilidades. Es interesante pues, el conocimiento de esta variable biofísica en los montes para una mejor gestión forestal.

### 1.3 LA COMUNIDAD VALENCIANA

¿Cómo son los montes valencianos?

Dentro del ecosistema mediterráneo, el *Pinus halepensis* (pino carrasco) es una de las especies más representativas: en términos porcentuales ocupa más del 60% del terreno arbolado de la comunidad Valenciana, unas 5000.000 hectáreas (tabla 1).

**Tabla 1. *Pinus Halepensis* en la comunidad Valenciana. Fuente propia a partir del Mapa forestal Nacional**

	SUP.ARBOLADA (Ha)	SUP. <i>Pinus Halepensis</i> (Ha)	%
ALICANTE	128304.68	106223.06	82.79
CASTELLÓN	268463.39	97235.29	36.22
VALENCIA	351052.39	264471.13	75.34
TOTAL	747820.47	467929.48	<b>62.57</b>

Es por tanto, de suma importancia conocer tanto la cantidad como la distribución de la biomasa en estas zonas de la Comunidad Valenciana.

### 1.4 LA TELEDETECCIÓN Y LA BIOMASA

La estimación de variables biofísicas de las masas forestales a partir de información de satélite datan de hace varias décadas. Se ha demostrado que mediante la teledetección es posible la estimación de variables biofísicas como el contenido de nitrógeno en plantas (Hansen y Schjoerring 2003; Martin *et al.* 2008) o el contenido en clorofila (Blackburn 1998; Broge y Mortensen 2002).

En cuanto a la biomasa para su cuantificación a pequeña escala es necesaria la utilización de información de mayor resolución como la que proporciona Landsat TM y ETM+ (Malmstrom *et al.* 2009; Meng *et al.* 2007; Todd *et al.* 1998, en Cáceres *et al.* 2015).

Se ha mejorado con los años la estimación de ésta variable, con el aumento de la resolución espacial de los satélites y añadiendo datos de otros sensores, sin embargo los modelos actuales tienen una gran complejidad en cuestión de toma de datos y además tienen un coste asociado que hacen que estos modelos no sean viables en pequeñas zonas.

Además los modelos propuestos para la estimación de la biomasa forestal se han referido mayoritariamente a ecosistemas productores, como las masas forestales de coníferas del norte de Europa donde éstas técnicas se utilizan para cuantificar la biomasa extraer, no a conservar.(Muukkonen y Heiskanen 2007).

En las zonas donde las masas forestales corren un peligro de conservación como en

zonas ecuatoriales y/o tropicales, también se han realizado estudios específicos.

En cambio, dejando de lado los modelos para zonas ecuatoriales y para bosques productores, muy pocos se han enfocado en las masas forestales del mediterráneo debido múltiples factores como la gran biodiversidad de las especies, la difícil orografía y la fuerte antropización realizada por el ser humano al medio. (Galidaki *et al.* 2017).

El enfoque más común para el cálculo de biomasa relaciona los datos de campo con índices de vegetación mediante modelos estadísticos (Azong Cho *et al.* 2007; Edirisinghe *et al.* 2012; Malmstrom *et al.* 2009; Meng *et al.* 2007; Muukkonen y Heiskanen 2007; Todd *et al.* 1998).

También la teledetección activa se ha utilizado para la estimación de biomasa. Se pueden encontrar trabajos donde se realiza la estimación de biomasa aérea a partir de datos LiDAR (García *et al.* 2010) así como a partir de datos de sensores pasivos e información multifuente (tabla 2).

**Tabla 2. Estudios previos. Fuente: Galidaki *et al.* (2017)**

**Table 1. Studies of AGB of Mediterranean forest and other wooded (OWL) land using remote sensing.**

Sensor type	Study	Vegetation type	Sensor	Resolution	RS variable (forest intermediate variable)	Achieved accuracy	Technique	Scale of the study (study area size in ha when mentioned)
Multispectral	Alrababah <i>et al.</i> (2011)	Forest	Landsat ETM, VHR aerial photography	30 m	Spectral bands (crown cover)	$R^2 = 0.56$	Linear regression	Local (81,400)
Multispectral	Calvão and Palmeirim (2004)	OWL	Landsat TM	30 m	Vegetation indices	Low	k-NN	Local
Multispectral	Chirici <i>et al.</i> (2008)	OWL	Landsat TM and ETM+	30 m	Spectral bands	$R^2 = 0.39$		Regional (250,00,00)
Multispectral	Fernández-Manso, Fernández-Manso, and Quintano (2014)	Forest	ASTER	30 m	Fraction images	$R^2_{adj} = 0.63$	LSMA, multiple linear regression	Local (7000)
Multispectral	Filella <i>et al.</i> (2004)	OWL	Landsat TM	30 m	Vegetation indices	$R^2 = 0.74$	Linear regression	Local
Multispectral	Gómez <i>et al.</i> (2014)	Forest	Landsat TM	30 m	Vegetation indices	70% overall accuracy	Wavelet transforms, decision trees	Local
Multispectral	Mallinis <i>et al.</i> (2004)	Forest	Landsat TM	30 m	Spectral bands, image transformations	$R^2 = 0.5$	Linear discriminant analysis	Local
Multispectral	Shoshany and Kamibad (2011)	OWL	Landsat TM	30 m	Vegetation indices	$R^2 = 0.98$	Nonlinear regression	Regional
Multispectral	Sousa <i>et al.</i> (2015)	Forest	Quickbird	0.70 m	Spectral bands (crown cover)	$R^2 = 0.67$	Linear regression/ GEOBIA	Local (1000)
Hyperspectral	De Jong, Pebesma, and Lacaze (2003)	Forest	DAIS	6 m	Vegetation indices	$R^2 = 0.56$ (log transformed)	Multiple linear regression	Local
Hyperspectral	Fava <i>et al.</i> (2009)	OWL	ASD Fieldspec	1.92 m	Vegetation indices	$R^2_{cv} = 0.73$	Linear regression	Local
Hyperspectral	Nijland <i>et al.</i> (2009)	Forest	Hymap	95 m	Hyperspectral bands	Increase of 17%	Linear regression	Local
SAR	Dobson <i>et al.</i> (1992)	Forest	AIRSAR	na	Backscatter intensity	$R^2 = 0.55-0.98$	Linear regression	Local
SAR	Svoray <i>et al.</i> (2001)	Forest	ERS-2	25 m	Backscatter	$R^2 = 0.85$	Linear regression	Regional
Lidar	Estornell <i>et al.</i> (2011)	OWL	Optech ALTM 2050	4 points/m <sup>2</sup>	Height metrics	$R^2 = 0.73$	Quadratic regression	Local (1000)
Lidar	Ferraz <i>et al.</i> , (2012b)	Forest	LiteMapper 5600	9.5 points/m <sup>2</sup>	Height metrics	$R^2 = 0.73-0.99$	Allometry, linear regression models	local
Lidar	García <i>et al.</i> (2010)	Forest	Optech-ALTM3033	1.5 points/m <sup>2</sup>	Return height and intensity	$R^2 = 0.70-0.90$	Allometry, linear regression	Local
Lidar	González-Ferreiro <i>et al.</i> (2013)	Forest	Optech-ALTM 2033	0.5 points/m <sup>2</sup> , 4 points/m <sup>2</sup>	Height and intensity metrics	$R^2 = 0.83-0.86$	Linear and exponential regression	Local
Lidar	Guerra-Hernández <i>et al.</i> (2016)	Forest	LEICA ALS50	0.5 points/m <sup>2</sup>	Height and canopy cover metrics	$R^2_{adj} = 0.74 - 0.83$	Multiple linear regression	Local
Lidar	Montaghi <i>et al.</i> (2013)	Forest	Review					

(Continued)

...Continúa

...Sigue

Table 1. (Continued).

Sensor type	Study	Vegetation type	Sensor	Resolution	RS variable (forest intermediate variable)	Achieved accuracy	Technique	Scale of the study (study area size in ha when mentioned)
Lidar	Riaño et al. (2004)	Forest	Toposys II	1point/ (1.73 × 0.11 m)	Height and intensity metrics	$R^2 = 0.84$	Exponential regression	Local
Lidar	Simonson et al. (2016)	Forest	Optech-ALTM3033/Leica ALS050	0.5 points/m <sup>2</sup> , 2 points/m <sup>2</sup>	Height metrics	$R^2 = 0.53$ (log transformed)	Linear regression	Local
Lidar	Velázquez-Martí et al. (2010)	OWL	Unidentified	8 points/m <sup>2</sup>	Height metrics (dendrometric and dasometric parameters)	$R^2 = 0.60-0.75$	Linear regression	Local (1000)
Multisource	Dahlin, Asner, and Field (2012)	Forest	AVIRIS, CAO	2.7 m, 2 points/m <sup>2</sup>	Vegetation indices, return height	$R^2 = 0.73$	Ordinary least squares regression	Local (500)
Multisource	Estornell et al. (2012)	OWL	Multispectral/Optech ALTM 2050	0.5 m, 8 points/m <sup>2</sup>	Spectral bands, vegetation indices, height metrics	$R^2 = 0.79$	Stepwise regressions	Local (1000)
Multisource	Gonzalez et al. (2010)	OWL	Optech ALTM 2050, QuickBird	1 points/m <sup>2</sup> , 6.2 m	Height metrics	OA = 70-97%	Linear regression, stepwise multiple regression	Local (6000)
Multisource	Hyde et al. (2006)	Forest	LVIS, STAR-3i, Landsat ETM+, Quickbird	1 Measurement/ 156 m <sup>2</sup> , 2.5 × 10 m, 30 m, 2 m	Height and intensity metrics, backscatter, image transformations, vegetation indices	$R^2 = 0.77-0.83$	Multiple regression	Regional (60,000)
Multisource	Svoray and Shoshany (2003)	OWL	Landsat TM, ERS-2	30 m	Fraction images, backscatter	$R^2 = 0.82$	Linear regression	Regional
Multisource	Tonolli et al. (2011)	Forest	Optech ALTM 3100C, IRS 1C LISS III	2 points/m <sup>2</sup> , 23.5 m, 70.8 m	Height and cover metrics, spectral bands, vegetation indices	$R^2 = 0.63-0.81$	Linear regression	Regional (300,000)

La gran mayoría de los trabajos realizados hasta la fecha se centran en la escala local, pero muy pocos se centran en escalas mayores.

Se ha constatado que la relación entre la biomasa y los valores de reflectividad no se relacionan mediante una regresión lineal y que los valores registrados por los sensores se saturan cuando alcanzan valores cercanos" (Vinué *et al.* 2019) por ello muchos modelos estadísticos han sido probados, según diferentes autores (tabla 3).

Tabla 3. Aprendizaje automático para cálculo de la biomasa. Fuente: Ali *et al* (2015)

Reference	Sensor	Parameter(s)	ML algorithm	Performance
[102]	ALOS PALSAR	Biomass	Bagging stochastic gradient boosting (BagSGB)	$R^2 = 0.90$
[103]	QuickBird	Height, biomass, volume	Support vector regression (SVR)	$R^2 = 0.72$
[104]	TerraSAR-X	Stem volume (v), basal area (a), height (h), diameter (d)	Random forest	RMSE (%): v = 34, a = 29, h = 14, d = 19.7
[105]	WorldView-2	Biomass	Random forest (RF), regression	RF: RMSE = 12.9%, regression: RMSE = 15.9%
[106]	Landsat	Above-ground woody biomass	RF	$R^2 = 0.943$
[107]	SPOT-5, LiDAR	Above-ground biomass	RF	$R^2 = 0.84$
[108]	ASTER	Volume (v), basal area (a), stems (s)	k-NN, SVR, RF	RF: $RMSE_v = 26.86$ , $RMSE_a = 18.39$ , $RMSE_s = 20.64$ ; SVR: $RMSE_v = 25.86$ , $RMSE_a = 19.35$ , $RMSE_s = 22.09$ ; k-NN: $RMSE_v = 28.54$ , $RMSE_a = 20.20$ , $RMSE_s = 20.64$
[79]	Landsat-7	Biomass	SVM	SVM = 84.62%; regressive analysis = 82.93%
[109]	Landsat time series	Forest biomass dynamics	Reduced major axis, gradient nearest neighbor, RF	RF: $RMSE_{Ari\ 2002} = 32.19$ , $RMSE_{Min\ nesota} = 39.23$

Otros estudios recientes han determinado los resultados de diferentes modelos de aprendizaje para la estimación de variables biofísicas, llegando a la conclusión que los procesos Gaussianos presentan un menor error cuadrático medio frente a otros métodos (Figura 1).

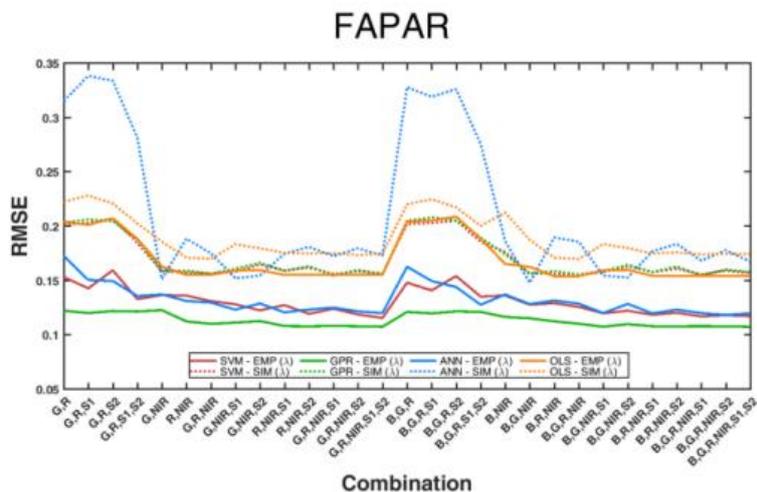


Figura 1. Comparativa métodos machine Learning para variables biofísicas. Fuente: Fuster.B (2017)

## 2. ANTECEDENTES Y JUSTIFICACIÓN

Este proyecto ha sido desarrollado en la empresa EOLAB, bajo el nombre SEN2MED, el cual ha sido financiado por el Institut Valencià de Competitivitat Empresarial N° Expediente IMIDTA/2018/104.



Y a su vez ha sido tutorizado por el equipo de teledetección del grupo de investigación ICTvsCC, Tecnologías de la Comunicación contra el cambio climático del instituto ITACA de la Universidad Politècnica de València.

Con este proyecto se pretende conseguir un modelo de cálculo de biomasa, simple, rápido y económico.

Esto permitirá realizar mapas de biomasa actuales y para la zona que se desee, para dotar a los técnicos forestales no sólo de una herramienta de estimación de biomasa, sino del conocimiento de la distribución de ésta variable biofísica así como del stock de carbono de los montes donde trabajan.

La innovación de éste proyecto es la utilización de imágenes de alta resolución espacial (10 m) y técnicas de aprendizaje automático junto con un inventario forestal propio (43 parcelas), para generación de un mapa de biomasa, así como un mapa de Stock de Carbono y cuantificación del CO<sub>2</sub> retenido en las zonas de *Pinus halepensis* de la Comunidad Valenciana.

### 3. OBJETIVOS

El objetivo del presente proyecto es la **creación del mapa de biomasa en zonas de *Pinus halepensis* para la Comunidad Valenciana, y de un mapa de stock de carbono, así como el cálculo del CO<sub>2</sub> retenido en los montes de *Pinus halepensis* de la Comunidad Valenciana.**

Este proceso conlleva la realización de las siguientes tareas:

1. **Generación de una base de datos** a partir de un inventario forestal actual e imágenes Sentinel-2:
  - 1.1 **Calcular** biomasa de las parcelas de muestreo tanto total como por fracciones (ramas, raíces...) además de área basimétrica, diámetro medio, diámetro cuadrático medio, densidad, índice de Hart-Becking etc.
  - 1.2 **Procesar** las imágenes para la extracción de los valores de reflectividad en superficie de todas las bandas en las parcelas de muestreo.
  - 1.3 **Producir** nuevas bandas para la base de datos: banda NDVI, ángulo solar, y banda de calidad.
2. **Entrenamiento mediante procesos Gaussianos:**
  - 2.1 **Testear** diferentes opciones de combinaciones de las bandas disponibles, determinar qué combinaciones podrían ser las mejores para el cálculo de la biomasa.
  - 2.2 **Seleccionar y validar** la mejor combinación atendiendo a valores de RMSE, coeficiente de correlación, bias, etc. Se obtendrán 2 máquinas de entrenamiento, una para cada tipo de estructura forestal.
3. **Aplicación del modelo a la zona de estudio**
4. **Extensión del modelo, generación del mapa de Biomasa y Stock de Carbono para la Comunidad Valenciana:**
  - 4.1 **Procesar** imágenes Sentinel -2 para la extensión del modelo a la Comunidad Valenciana.
  - 4.2 **Aplicar** el modelo a toda la Comunidad Valenciana.
  - 4.3 **Generar** mapa de biomasa y stock de carbono de la Comunidad Valenciana.
  - 4.4 **Calcular** retención de CO<sub>2</sub> en los montes de *pinus halepensis* de la Comunidad Valenciana.

## 4. MATERIALES

### 4.1 INVENTARIO FORESTAL

El inventario forestal utilizado en el presente proyecto se realizó el 9 de Febrero de 2017 por el Ingeniero Forestal y Máster en Teledetección D. David Vinué Visús (tutor experimental de éste proyecto).

El inventario se ha realizado siguiendo los procedimientos del Inventario Forestal Nacional (IFN3), se tomaron tanto variables dasométricas (de la masa forestal) como dendrométricas (forma del individuo). También se georreferenció cada parcela mediante GPS.

Estas parcelas tienen una geometría circular de entre 10-15 metros de radio. En cada una de éstas parcelas se tomaron datos de altura con un distanciometro laser Trimble Laser Ace 1000 Rangefinder y diámetro con una forcípula forestal, de todos los individuos (pinos).

### 4.2 IMÁGENES SATELITALES SENTINEL-2

Las imágenes Sentinel -2 utilizadas en este proyecto se descargaron de la página web de la Agencia Espacial Europea<sup>1</sup>.

Las imágenes Sentinel-2 tienen diferentes niveles de procesado, **1C** (con valores de reflectividad TOA sin corrección atmosférica) **2A** (valores BOA, corregida atmosféricamente) (tabla 4).

**Tabla 4. Tipos de productos Sentinel 2. Fuente: <https://earth.esa.int/web/Sentinel/user-guides/Sentinel-2-msi/product-types>**

Name	High-level Description	Production & Distribution	Data Volume
Level-1C	Top-of-atmosphere reflectances in cartographic geometry	Systematic generation and on-line distribution	600 MB (each 100x100 km <sup>2</sup> )
Level-2A	Bottom-of-atmosphere reflectance in cartographic geometry	Systematic generation and on-line distribution and generation on user side (using Sentinel-2 Toolbox)	800 MB (each 100x100 km <sup>2</sup> )

Estas imágenes tienen diferentes bandas con resoluciones diferentes (tablas 5,6 y 7).

**Tabla 5. Bandas de 10 metros de resolución espacial. Fuente: <https://earth.esa.int/web/Sentinel/user-guides/Sentinel-2-msi/resolutions/radiometric>**

Band number	S2A		S2B		L <sub>ref</sub> (reference radiance) (W m <sup>-2</sup> sr <sup>-1</sup> μm <sup>-1</sup> )	SNR @ Lref
	Central wavelength (nm)	Bandwidth (nm)	Central wavelength (nm)	Bandwidth (nm)		
2	492.4	98	492.1	98	128	154
3	559.8	45	559.0	46	128	168
4	664.6	38	664.9	39	108	142
8	832.8	145	832.9	133	103	174

<sup>1</sup> <https://scihub.copernicus.eu/dhus/>, (última, Julio.2019)

**Tabla 6. . Bandas de 20 metros de resolución espacial Fuente: <https://earth.esa.int/web/Sentinel/user-guides/Sentinel-2-msi/resolutions/radiometric>**

Band number	S2A		S2B		$L_{ref}$ (reference radiance) ( $W\ m^{-2}\ sr^{-1}\ \mu m^{-1}$ )	SNR @ $L_{ref}$
	Central wavelength (nm)	Bandwidth (nm)	Central wavelength (nm)	Bandwidth (nm)		
5	704.1	19	703.8	20	74.5	117
6	740.5	18	739.1	18	68	89
7	782.8	28	779.7	28	67	105
8a	864.7	33	864.0	32	52.5	72
11	1613.7	143	1610.4	141	4	100
12	2202.4	242	2185.7	238	1.5	100

**Tabla 7. Bandas de 60 metros de resolución espacial. Fuente: <https://earth.esa.int/web/Sentinel/user-guides/Sentinel-2-msi/resolutions/radiometric>**

Band number	S2A		S2B		$L_{ref}$ (reference radiance) ( $W\ m^{-2}\ sr^{-1}\ \mu m^{-1}$ )	SNR @ $L_{ref}$
	Central wavelength (nm)	Bandwidth (nm)	Central wavelength (nm)	Bandwidth (nm)		
1	442.7	27	442.2	45	129	129
9	945.1	26	943.2	27	9	114
10	1373.5	75	1376.9	76	6	50

Para el presente trabajo se descargaron un total de 7 imágenes que abarcaban la totalidad de la Comunidad Valenciana (tabla 8 y Fig. 2).



**Figura 2. Zonas UTM Sentinel-2 Comunidad Valenciana. Fuente: propia**

**Tabla 8. Imágenes empleadas en el proyecto**

Imágenes Sentinel 2	
Zona	Fecha
30TYL	06/05/2017
30SXH	15/06/2017
30SXJ	15/06/2017
30SYH	15/06/2017
30SYJ	15/06/2017
30TXK	05/07/2017
30TYK	05/07/2017

Se han utilizado todas las imágenes en el huso 30, y con un nivel de procesamiento 2A para evitar así un largo tiempo de procesado de corrección atmosférica.

### 4.3 CAPAS VECTORIALES

Las capas utilizadas en el presente proyecto han sido las siguientes (tabla 9).

**Tabla 9. Capas empleadas en el proyecto**

Capa	Descripción	Descarga
MUNICIPIOS	En formato shape polígono. Obtenida del centro de descargas del Instituto geográfico nacional, dentro de la sección información geográfica de referencia, capa líneas límite municipales (Ministerio de Fomento)	<a href="http://centrodedescargas.cnig.es/CentroDescargas/index.jsp">http://centrodedescargas.cnig.es/CentroDescargas/index.jsp</a>
PROVINCIAS	En formato shape polígono. (ministerio de Agricultura Alimentación y medio ambiente)	<a href="https://servicio.mapama.gob.es/si_a/visualizacion/descargas/mapas.jsp">https://servicio.mapama.gob.es/si_a/visualizacion/descargas/mapas.jsp</a>
MAPA FORESTAL NACIONAL	En formato shape polígono (Ministerio para la transición ecológica). Descargado por provincias	<a href="https://www.miteco.gob.es/es/biodiversidad/servicios/banco-datos-naturaleza/informacion-disponible/mfe50_descargas_com_unidad_valenciana.aspx">https://www.miteco.gob.es/es/biodiversidad/servicios/banco-datos-naturaleza/informacion-disponible/mfe50_descargas_com_unidad_valenciana.aspx</a>
IMAGEN BASE	SERVICIO WMTS Imágenes de satélite Spot y ortofotos PNOA (Ministerio de fomento)	<a href="http://www.ign.es/wmts/pnoa-ma">http://www.ign.es/wmts/pnoa-ma</a>

Las demás capas vectoriales empleadas en este proyecto son de producción propia a partir de las capas citadas anteriormente.

**HALEPENSIS\_SEGMENTACION. Shp** capa generada a partir del MFN del 2007 seleccionando sólo las entradas con Id\_ForArb con valor 24 correspondiente la especie de *Pinus Halepensis* Mill.

**BUFFER\_XXX.shp** capa buffer de 15 metros de radio de las parcelas de estudio para la segmentación de datos LiDAR.



#### 4.4 LIDAR-PNOA

Se utilizaron datos LiDAR-PNOA de segunda cobertura del 12 y 13 de marzo de 2018, con una densidad de 0.5 ptos/m<sup>2</sup> y una precisión mejor de 0.20 metros en altimetría.

Según el Centro de Descargas del CNIG “Los ficheros son de 2x2 km de extensión en formato .LAZ y se pueden descargar a través del Centro de Descargas del Cnig. El sistema geodésico de referencia es ETRS89 en la Península, Islas Baleares, Ceuta y Melilla, y REGCAN95 en las Islas Canarias (ambos sistemas compatibles con WGS84) y proyección UTM en el huso correspondiente a cada fichero. Las coordenadas Z son altitudes ortométricas.”

## 5. METODOLOGÍA

De una manera esquemática la metodología a seguir es la siguiente:



Para la creación de los estos mapas de biomasa y stock de carbono se necesita:

- Generar una base de datos para entrenar el modelo de aprendizaje automático (datos de campo + LiDAR + Reflectividades).
- Determinar la combinación de variables a probar en el modelo.
- Aplicar procesos Gaussianos y decidir el mejor modelo.
- Aplicar el modelo a la imagen de la zona de estudio.
- Extensión del modelo a la Comunidad Valenciana para la generación del mapa de biomasa.
- Generación del mapa de stock de carbono.
- Cálculo de CO<sub>2</sub> retenido en los montes de *Pinus halepensis*.

### 5.1 GENERACIÓN DE LA BASE DE DATOS DEL ENTRENAMIENTO

La base de datos, se compone de datos de campo, estadísticos LiDAR PNOA y reflectividades obtenidas de las de imágenes Sentinel 2.

#### 5.1.1 DATOS DE CAMPO

Se inventariaron un total de 43 parcelas, repartidas entre los municipios de Liria y Enguera (Comunidad Valenciana).

Según algunos autores "se aconseja realizar, al menos, 20 parcelas de muestreo por estrato" (Naesset, 2002) en este proyecto se estudian 2 estratos diferentes, por lo que la muestra será de como mínimo 40 parcelas.

Estas parcelas, fueron elegidas por un técnico competente para garantizar la representatividad del monte mediterráneo de *Pinus halepensis* en la muestra. En este proyecto se analizan dos tipos de estructuras forestales: El monte bravo y la combinación de latizal y fustal (Fig. 3).

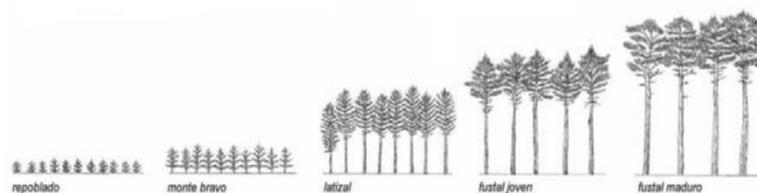
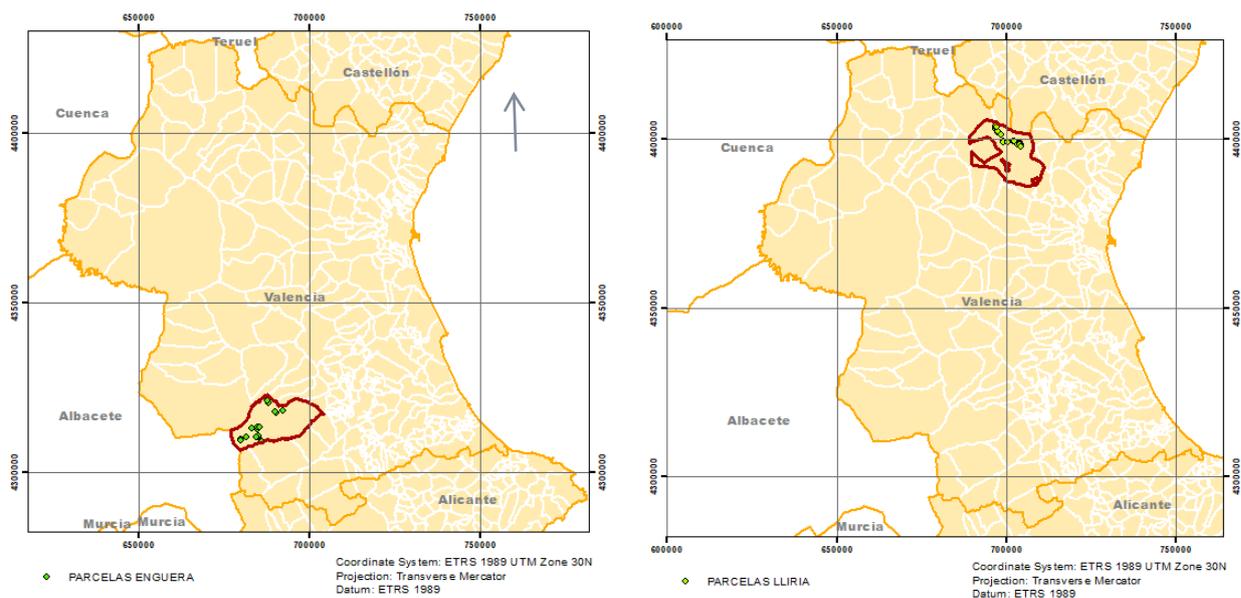


Figura 3. Estructuras forestales. Fuente: Atlas Forestal de Castilla y León

Las parcelas se encuentran en la provincia de Valencia, más concretamente en los municipios de Enguera y Llíria.

El municipio de Enguera se encuentra al sur-oeste de la provincia de Valencia, y pertenece a la comarca del Canal de Navarrés. En este municipio se ha realizado el inventario de 22 parcelas de campo, incluyendo entre ellas parcelas de suelo.

El Municipio de Llíria se encuentra al norte de la provincia de Valencia limítrofe con la provincia de Castellón, situado en la comarca del camp del Turia. Dentro de este municipio se han inventariado un total de 21 parcelas. (Fig. 4).



**Figura 4. Situación parcelas de estudio**

## CÁLCULO DE BIOMASAY OTRAS VARIABLES

Para calcular la biomasa total del árbol así como de cada fracción del mismo hay una gran diversidad de modelos aunque todos ellos derivan de funciones lineales o logarítmicas (Parresol, 1999). Los modelos más utilizados hoy en día son los alométricos, con forma potencial, y se calculan a partir del diámetro medio y de la altura total del árbol.

La alometría es el desarrollo de una parte del organismo en relación al desarrollo total<sup>2</sup>. En el presente proyecto se han usado las ecuaciones alométricas para *Pinus halepensis* Mill. de Ruiz-Peinado *et al.* (2011). Para los valores de altura total y diámetro medio, separa la biomasa en fracciones para el fuste con corteza ( $W_s$ ) (ec.1), las ramas gruesas de más de 7 cm de diámetro ( $W_{b7}$ ) (ec.2), dependiendo de su importancia según los pies sean de más de 27,5 cm de diámetro o de menos, las ramas medias entre 2 y 7 cm ( $W_{b2-7}$ ) (ec. 3) y las ramas finas de menos de 2 cm junto con las acículas ( $W_{b2+n}$ ) (ec.4), e incluyendo la biomasa de las raíces ( $W_r$ ) (ec .5) (tabla 10).

<sup>2</sup> Fuente: <https://www.definiciones-de.com/Definicion/de/alometria.php> © Definiciones-de.com

**Tabla 10. Ecuaciones alométricas para el cálculo de biomasa según Ruiz-Peinado *et al* (2011)**

Ecuaciones alométricas		
<b>Fuste</b>	$W_s = 0,0139 * d^2 * h$	(ec. 1)
<b>Ramas gruesas</b>	Si $d \leq 27,5$ cm: $Z = 0$ ; si $d > 27,5$ cm: $Z = 1$	
	$W_{b7} = [3,926 * (d-27,5)] * Z$	(ec. 2)
<b>Ramas medias</b>	$W_{b2-7} = 4,257 + 0.00506 * d^2 * h - 0,0722 * d * h$	(ec. 3)
<b>Ramas finas y acículas</b>	$W_{b2+n} = 6,197 + 0.00932 * d^2 * h - 0,0686 * d * h$	(ec. 4)
<b>Raíces</b>	$W_r = 0,0785 * d^2$	(ec. 5)
<b>TOTAL ARBOL</b>	$W_s + W_{b7} + W_{b2-7} + W_{b2+n} + W_r$	(ec. 6)

La biomasa total de una parcela será la suma de la biomasa de cada uno de los árboles presentes en las parcelas. Después se pasará este valor a toneladas de biomasa por hectárea.

Además también se ha calculado para cada parcela:

- Diámetro medio
- Área basimétrica (relación entre las secciones normales de los árboles de un espacio forestal y la superficie de terreno que ocupan<sup>3</sup>)

$$G = \pi * \left( \frac{D_{medio}}{100} \right)^2 \quad (ec.7)$$

- Densidad de pies (por hectárea)

$$Densidad = \frac{10000 * N_{pies}}{Superficie} \quad (ec.8)$$

- Índice Hart-Becking (relación entre el espaciamiento medio del arbolado y su altura dominante<sup>3</sup>)

$$HB = \sqrt{\left( \frac{10000}{Densidad} \right) * \frac{1}{H_{max}}} * 100 \quad (ec.9)$$

- Altura media y máxima

Además atendiendo a la cantidad de biomasa calculada se añadió una clasificación por medio de código (tabla 11) siendo:

**Tabla 11. Clasificación de las estructuras forestales para la base de datos de entrenamiento**

CÓDIGO	NOMBRE	BIOMASA(t/ha)
1	Monte bravo	<42
2	Latizal- Fustal	>42
3	Suelo	≈0

Estos códigos servirán posteriormente para separar la base de datos, y aplicar los procesos de aprendizaje automático de manera separada, para cada tipo de estructura.

Una vez calculados todos los datos necesarios se obtiene una base de datos (BBDD) para el entrenamiento (Anejo 2).

<sup>3</sup> Fuente: Wikipedia

### 5.1.2 DATOS LIDAR

Se han utilizado 18 archivos LiDAR de las 2 zonas de estudio, de los cuales se obtienen los estadísticos de las nubes de puntos. Para ello se ha elaborado una cadena de procesado (figura 5).

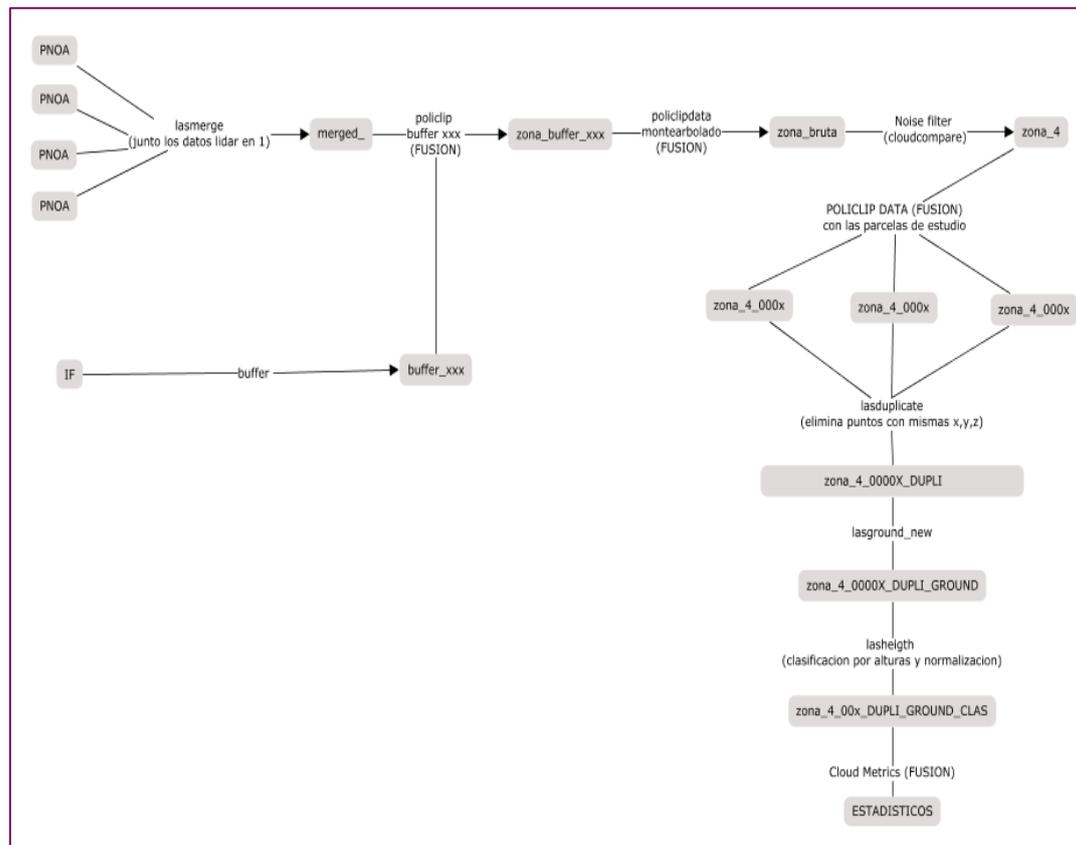


Figura 5. Cadena de procesado de datos LiDAR-PNOA

Los *softwares* utilizados para el procesado de la nube de puntos son FUSION, LAStools y Cloudcompare todos de acceso libre y gratuito. Los pasos a seguir para la obtención de los estadísticos se pueden encontrar en el Anejo 3.

El resultado del proceso es una serie de archivos .txt para cada parcela con más de 100 estadísticos diferentes, todos los archivos resultantes se han unificado en una misma tabla (Anejo 4), que es la que se ha incorporado a la base de datos.

### 5.1.3 DATOS SENTINEL -2

Se descargaron 2 imágenes Sentinel para la extracción de reflectividades en los píxeles de la zona de estudio. Aunque se ha automatizado el proceso de corrección atmosférica (Anejo 5) se han descargado imágenes corregidas (2A).

En la BBDD del entrenamiento se incluyen las reflectividades de las todas la bandas de la imagen Sentinel 2, además de las bandas suplementarias, NDVI, ángulo solar y banda de calidad. (Tabla 12).

**Tabla 12. Reflectividades imágenes Sentinel-2**

Banda	Nombre	Resolución
Banda 1	Deep blue	60
Banda 2	Red	10
Banda 3	Green	10
Banda 4	Blue	10
Banda 5	RE1 Red Edge	20
Banda 6	RE2 Red Edge	20
Banda 7	RE3 Red Edge	20
Banda 8	NIR	10
Banda 8 <sup>a</sup>	NIR	20
Banda 11	SWIR 1 (Short Wave Infrared)	20
Banda 12	SWIR 2 (Short Wave Infrared)	20
Banda ANGULO SOLAR	zenit	10
Banda NDVI	$NDVI = (NIR - R) / (NIR + R)$	10
Banda DE CALIDAD	SCL	10

Para la generación de dichas bandas y la homogenización de todas ellas a una resolución de 10 metros se han empleado programas IDL creados por D. David Vinué Visús que se adaptaron para este proyecto (PROCESADO\_S2 y CABECERO S2).

Una vez ejecutados y finalizados los programas, se genera una imagen total. Georreferenciada, con todas las bandas a resolución 10 metros, incluido el ángulo solar leído en el cabecero, el NDVI y la banda de calidad, en formato ENVI.

Para la extracción de reflectividades de la imagen Envi, se emplea otro código de IDL, que extrae el valor de los píxeles de las parcelas de estudio. (EXTRACTOR\_S2).

Estos datos se añaden a la base de datos. Una vez adjuntados, y como último paso para la preparación de la misma, se divide la BBDD en 3 subconjuntos para entrenar y validar los procesos gaussianos.

Todos los códigos IDL en el Anejo 6.

Base de datos en el Anejo 7.

## 5.2 ENTRENAMIENTO Y VALIDACIÓN DE LOS PROCESOS GAUSSIANOS

Los procesos Gaussianos son un método de aprendizaje automático o *machine learning*. El *machine learning* consiste en una serie de algoritmos que mejoran y aprenden de manera autónoma gracias a los datos. Dicho de otra manera: son algoritmos estadísticos que obtienen las relaciones entre los datos de forma automática.

En el Anejo 8 se puede encontrar una breve explicación de los métodos de aprendizaje automático, tipos y descripción de varios de los métodos existentes, entre ellos el que se va a utilizar en este proyecto.

Para el presente proyecto se ha elegido utilizar el modelo de **regresión por procesos**

**Gaussianos con función kernel exponencial** ya que:

- Tiene una configuración relativamente sencilla, y no es necesario una gran cantidad de muestras para llegar a una solución óptima.
- Se obtienen valores de relevancia para cada una de las variables independientes.
- Pocos parámetros a adaptar para la maximizar la función de probabilidad.
- Proporciona intervalos de predicción.

Se probaron los procesos Gaussianos para las siguientes combinaciones de información (tabla 13). (Anejo 9)

**Tabla 13. Combinaciones testeadas en los Procesos Gaussianos**

<b>Combinaciones</b>
<b>Sentinel +LiDAR</b>
<b>Sentinel</b>
<b>LiDAR</b>
<b>NDVI+ KURT+ P60</b>
<b>MIX</b>
<b>NDVI+8A</b>
<b>NDVI+8A+P90</b>

El entrenamiento de las máquinas se hace mediante programa informático en entorno Matlab. Se establecen las variables de entrada (*inputs*) y la variable de salida (*output*) correspondiente a esas entradas, así la maquina "aprende" a partir de unos pocos ejemplos.

Para éste proyecto se emplean las bandas NDVI + 8A.

La validación de los resultados se realiza mediante otro programa Matlab. Dando como resultado la representación gráfica de la regresión, para una mejor interpretación además de algunos datos estadísticos. (Anejo 10)

### **5.3 APLICACIÓN DE LAS MÁQUINAS ENTRENADAS PARA LA GENERACIÓN DE IMÁGENES DE BIOMASA**

La aplicación de las máquinas entrenadas se realiza a través de un código Matlab, cuyos *inputs* son las bandas NDVI y 8A de la imagen Sentinel 2 (figura 6) y cuyo *output* es el valor de biomasa. Dicho de otra manera, el programa lee de cada pixel de la imagen, el valor NDVI y el valor de la banda 8A, y tras aplicar el algoritmo de regresión nos devuelve el valor de biomasa en toneladas por hectárea.(figura 7)



Figura 6. Imagen Sentinel-2, Visualización en color verdadero



Figura 7. Resultado código Matlab para generación de imágenes de Biomasa

Códigos Matlab en Anejo 10.

#### 5.4 GENERACIÓN MAPAS DE BIOMASA DE LA COMUNIDAD VALENCIANA

Para poder obtener el mapa de biomasa de la Comunidad Valenciana, hay que aplicar las máquinas entrenadas a las imágenes Sentinel -2 que cubran el total del territorio

Las imágenes utilizadas y sus fechas de adquisición se pueden consultar en la tabla 8

Se realiza para cada imagen el proceso indicado en la figura 8:

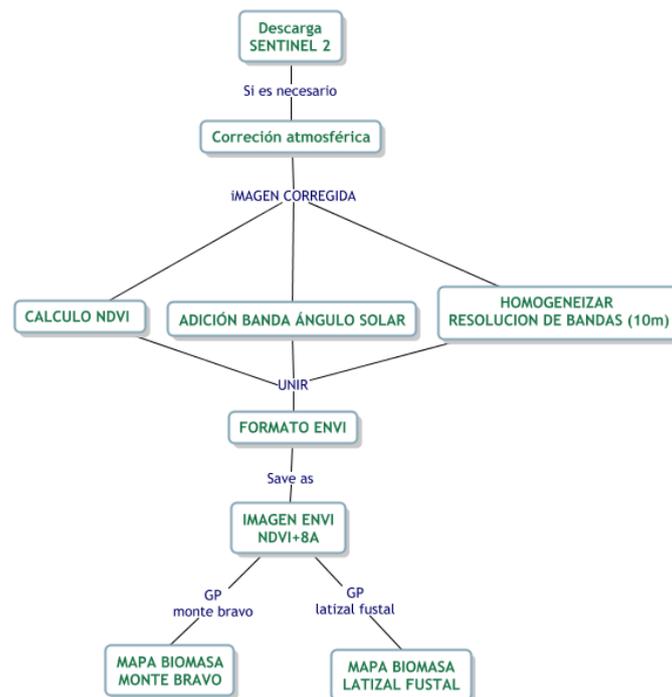


Figura 8. Procesado para la generación de mapas de Biomasa

1. Se descargan las imágenes.
2. Se corrigen (en éste caso no es necesario, ya que todas las imágenes empleadas son de un nivel de procesado 2A por lo que ya están corregidas).
3. Mediante código IDL citado anteriormente, se genera una imagen Envi con todas las bandas (para su posible consulta posterior).
4. Se genera una nueva imagen con Envi, con únicamente las bandas de NDVI y 8A para la lectura por el programa Matlab de generación de imágenes de biomasa, Se aplican los procesos gaussianos.
  - a. Gp de monte bravo para generación de imágenes de biomasa en monte bravo
  - b. Gp de latizal fustal para generación de imágenes de biomasa en latizal fustal.

Códigos en el Anejo 10.

A partir de estas imágenes se generan diferentes mapas de biomasa (en zonas de *Pinus halepensis* y para toda la Comunidad Valenciana) mediante las siguientes herramientas SiG:

- Extract by mask
- Mosaic to new Raster

Generación de mapas de biomasa, segmentación SIG (Anejo 11).

## 5.5 GENERACIÓN DEL MAPA DE STOCK DE CARBONO

Para la generación del mapa de stock de carbono y para la cuantificación del CO<sub>2</sub> se ha partido del mapa de biomasa en zonas de *Pinus halepensis*.

### 5.5.1 CONVERSIÓN DE VALORES DE t/ha a t/pixel

En los mapas de biomasa, a cada pixel se le asocia un valor en t/ha, hecho que no es real, ya que los pixeles de las imágenes son de 10 x 10 metros es decir 100 m<sup>2</sup>, es decir un pixel es la 0.01 parte de una hectárea. O dicho de otra manera, en una hectárea hay 100 pixeles por lo tanto para pasar de t/ha a t/pixel (Figura 9):

$$\frac{1t}{ha} * \frac{1ha}{100pixel} = \frac{t}{pixel} \quad (\text{ec. 10})$$

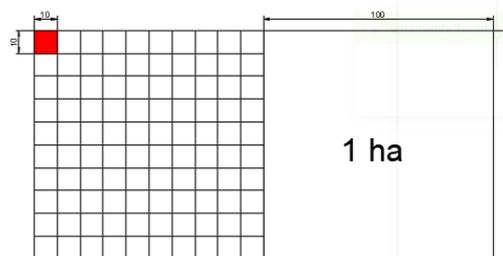


Figura 9. Esquema hectárea-píxel

Por lo que el primer paso es multiplicar cada uno de los pixeles por 0.01 para conseguir obtener el valor de biomasa para la extensión del pixel, se realizó directamente desde el SIG mediante la herramienta *raster calculator*.

### 5.5.2 CÁLCULO DE BIOMASA EN LA ZONA DE *Pinus Halepensis*

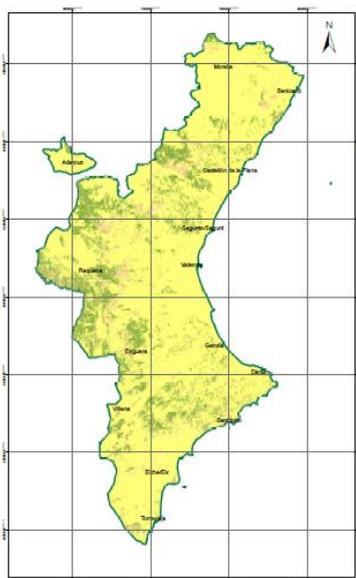


Figura 10. Mapa base para el cálculo de CO<sub>2</sub> retenido

Una vez se obtuvo el mapa de biomasa por píxel (Figura 10) se sumaron todos los pixeles para calcular la cantidad de biomasa en toneladas en los *Pinus halepensis* de la Comunidad Valenciana, esto se ha realizado mediante la herramienta *Zonal statistics*.

### 5.5.3 CONVERSIÓN DE BIOMASA A CARBONO

Una vez obtenido el valor de biomasa se aplica el factor de 0,5 kg de carbono por kg de biomasa (0,5kg C/ kg) para la parte aérea y de 0,481 (0,481kg C/kg) para la subterránea (Ritson y Sochacki 2003) para obtener la cantidad de carbono almacenado.

En la base de datos, se puede ver que la biomasa en raíces de una parcela representa el 23% por lo que la parte aérea será el 77% (Tabla 14)

**Tabla 14. Biomasa por fracciones arbóreas**

Tronco	%	R. gruesas	%	R. medias	%	R. finas	%	Raíz	%	W (Kg)
1,304.19	0.41	7.07	0.00	280.41	0.09	726.39	0.23	844.81	0.27	3,162.46
1,626.65	0.41	47.11	0.01	347.43	0.09	903.35	0.23	1,016.52	0.26	3,941.06
1,583.56	0.42	66.74	0.02	343.92	0.09	877.42	0.23	920.20	0.24	3,791.84
1,678.75	0.42	14.53	0.00	351.06	0.09	921.57	0.23	990.25	0.25	3,956.16
1,809.95	0.39	255.19	0.06	420.20	0.09	1,020.74	0.22	1,082.74	0.24	4,592.34
656.33	0.38	0.00	0.00	143.83	0.08	422.90	0.25	485.50	0.28	1,708.56
201.08	0.18	0.00	0.00	240.94	0.22	447.02	0.41	209.01	0.19	1,098.05
692.07	0.38	0.00	0.00	159.84	0.09	466.93	0.25	513.47	0.28	1,832.31
189.53	0.38	0.00	0.00	46.02	0.09	122.47	0.24	146.74	0.29	504.76
69.56	0.22	0.00	0.00	53.52	0.17	103.56	0.33	87.06	0.28	313.69
129.66	0.18	0.00	0.00	155.70	0.21	280.42	0.39	160.32	0.22	726.10
601.96	0.33	19.63	0.01	260.64	0.14	561.43	0.30	402.80	0.22	1,846.46
1,659.78	0.44	70.67	0.02	349.57	0.09	901.08	0.24	778.15	0.21	3,759.26
2,111.83	0.41	333.71	0.06	533.52	0.10	1,216.14	0.23	1,015.73	0.19	5,210.93
1,358.49	0.45	54.96	0.02	285.79	0.10	731.91	0.24	567.56	0.19	2,998.71
1,253.50	0.43	35.33	0.01	257.15	0.09	681.37	0.23	678.22	0.23	2,905.58
1,957.53	0.44	49.08	0.01	407.23	0.09	1,063.28	0.24	992.18	0.22	4,469.30
1,516.62	0.42	121.71	0.03	339.77	0.09	840.98	0.23	765.71	0.21	3,584.78
1,400.50	0.43	47.11	0.01	292.22	0.09	764.57	0.24	748.75	0.23	3,253.16
1,628.07	0.41	138.59	0.03	368.89	0.09	928.52	0.23	915.35	0.23	3,979.42
1,065.31	0.44	60.07	0.02	223.79	0.09	588.59	0.24	489.63	0.20	2,427.40
3,105.86	0.45	54.77	0.01	639.02	0.09	1,688.58	0.25	1,388.81	0.20	6,877.05
<b>PROMEDIO</b>	<b>0.38</b>	<b>62.56</b>	<b>0.02</b>	<b>295.48</b>	<b>0.11</b>	<b>739.06</b>	<b>0.26</b>	<b>690.89</b>	<b>0.23</b>	

Por lo tanto si se aplican estos porcentajes y factores, se consigue el mapa de carbono de la Comunitat Valenciana:

$$(kg \text{ Biomasa} * 0.23) * \left(0.481 * \frac{kg \text{ C}}{kg \text{ bi}}\right) + (kg \text{ Biomasa} * 0.77) * \left(0.50 * \frac{kg \text{ C}}{kg \text{ bi}}\right) =$$

$$Kg \text{ Biomasa} * 0.4954 \frac{kg \text{ C}}{kg \text{ bi}} = \text{---} kgC \quad (\text{ec.11})$$

Esta es la relación que aplicamos a cada pixel de nuestro mapa de biomasa para obtener el mapa de stock de carbono en la Comunidad Valenciana.

En resumen: para la generación del mapa de stock de carbono, se tomó el mapa de biomasa y con la herramienta Raster calculator se multiplico por 0.4954 para sacar un mapa en toneladas de carbono por hectárea, (Ver Cartografía Generada)

En cambio, para la cuantificación del stock de carbono, se realizó de misma manera que para la cuantificación de biomasa.

### 5.6 CUANTIFICACIÓN DE CO<sub>2</sub> RETENIDO Y RELACIÓN ENTRE VARIABLES

Después de haber obtenido el mapa de Stock de Carbono en la Comunidad Valenciana, Stock de Carbono en las zonas de *Pinus halepensis* y las toneladas de carbono almacenadas en los montes de *Pinus halepensis* de la Comunidad Valenciana, solamente bastará aplicar la relación estequiometría entre el carbono y el dióxido de carbono (3.67 kg CO<sub>2</sub>/kg C) para obtener el CO<sub>2</sub> retenido en estas masas.

Una manera rápida de ver la relación entre las variables calculadas en las zonas de *Pinus halepensis* (Figura 11)

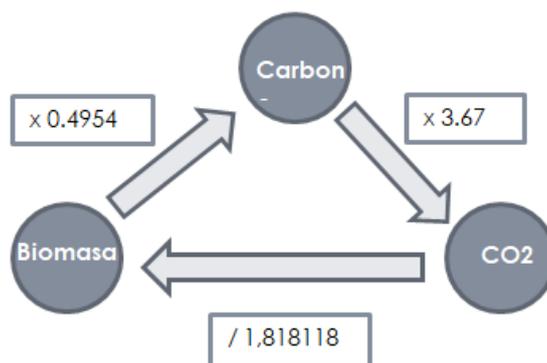


Figura 11. Esquema relación entre Biomasa Carbono y CO<sub>2</sub>

## 6. RESULTADOS Y DISCUSIÓN

### 6.1 RESULTADOS

La metodología expuesta en el apartado anterior nos da como resultado 4 mapas:

1. Mapa de biomasa para la Comunidad Valenciana
2. Mapa de biomasa para las zonas de *Pinus halepensis* de la Comunidad Valenciana
3. Mapa de stock de carbono de la Comunidad Valenciana
4. Mapa de stock de carbono para las zonas de *Pinus halepensis* de la Comunidad Valenciana  
(Ver 7. Cartografía generada)

Éstos se realizaron a partir de algoritmos de aprendizaje automático, testeando diferentes combinaciones de información cuyos resultados de validación fueron los siguientes. (tabla15)

**Tabla 15. . Estadísticas de la validación de los modelos Gaussianos**

BANDAS	BIAS	S	R <sup>2</sup>	RMSE
SENTINEL+LIDAR	1	14.51	0.51	14.54
SENTINEL	-0.01	17.43	0.29	17.43
LIDAR	0.25	13.99	0.55	13.99
NDVI+KURT+P60	-0.25	13.86	0.55	13.86
MIX	1.48	14.05	0.56	14.13
NDVI+8A	-0.26	7.75	0.88	7.76
NDVI+8A+P90	-1.14	7.43	0.89	7.51

Dónde:

Gaussian Statistics	Comment
RMSE: Root Mean Square Deviation	El RMSE calculado entre los valores del suelo y del producto Indica la Precisión (Error Total).
B: Mean Bias	Diferencia entre los valores medios del suelo y del producto. Indicativo de la exactitud y posible compensación. (Sesgo)
S: Standard deviation	Desviación standard de la diferencia entre pares. Indica precisión.
R: Correlation coefficient	Indica la potencia descriptiva de la prueba de precisión lineal.
Major Axis Regression (slope, offset)	Indica algún posible sesgo.

La mejor combinación incluía datos LiDAR, pero debido a que el propósito del proyecto era obtener el mapa de la Comunidad Valenciana, el uso de datos LiDAR, con todo el procesado que conlleva, no era viable dado el gasto computacional y de tiempo para la escasa mejora que aportaba.

**Por lo tanto se decidió utilizar la combinación de bandas NDVI+8A.**

Se entrenaron 2 máquinas diferentes, una para latizal – fustal (Figura 12 b) y otra para

monte bravo (Figura 12 a)

Los resultados de la validación de estas 2 máquinas fueron los siguientes:

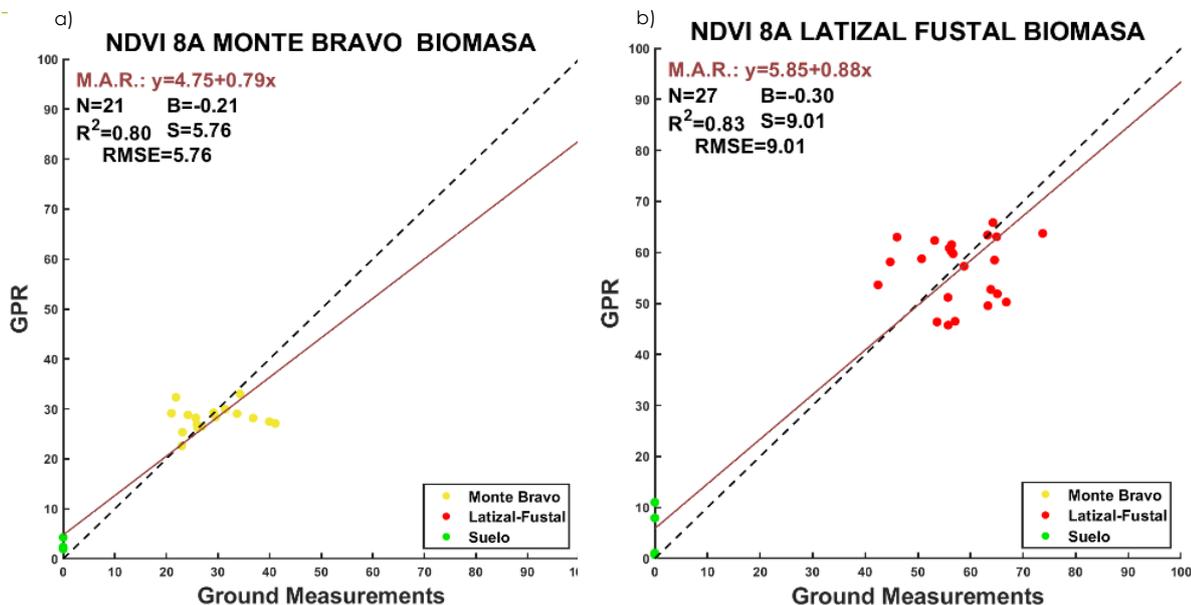


Figura 12. Resultados gráficos de la validación de los procesos Gaussianos para latizal- fustal (b) y monte bravo(a), de las bandas 8A y NDVI

Que de una manera conjunta (Figura 13)

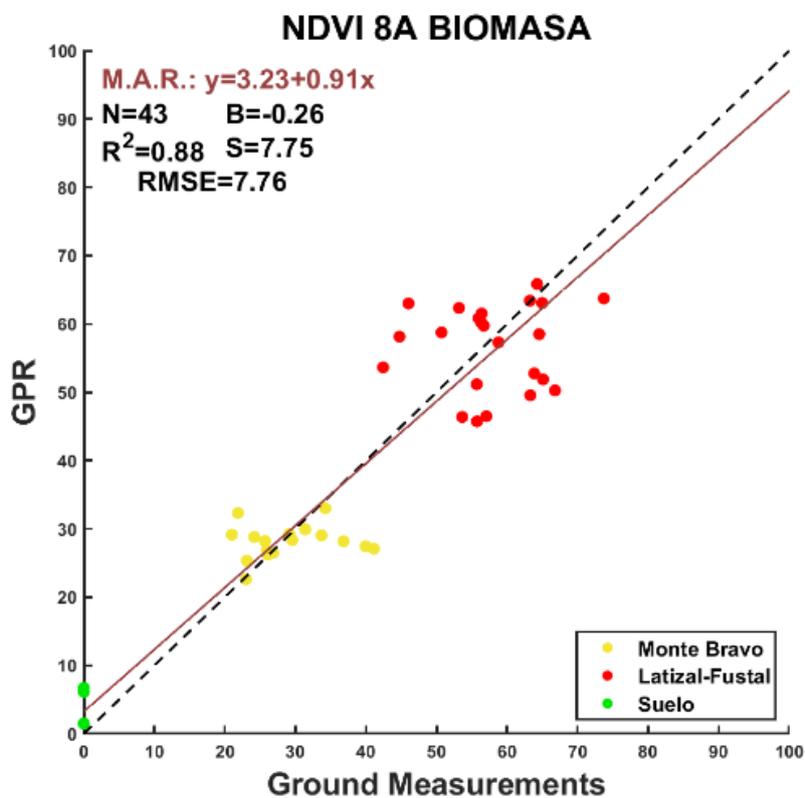


Figura 13. Validación conjunta del modelo para las bandas NDVI + 8A

Se pueden consultar las representaciones gráficas de la regresión de las combinaciones no escogidas en el Anejo 9.

Por consiguiente, al final del entrenamiento obtenemos 3 máquinas diferentes:

- Para monte bravo
- Para latizal y fustal
- Para el conjunto de monte bravo, latizal y fustal.

En éste proyecto se decidió aplicar las máquinas para monte bravo y para latizal y fustal por separado, y una vez obtenido los productos, segmentarlos mediante un SIG de escritorio.

Una vez descargadas y procesadas la imágenes Sentinel-2 se guardaron mediante el comando *Envi Save As Envi Standard* las Imágenes solo con las bandas NDVI + 8A que rebajaba el peso de las mismas de 6 Gb a 1 G para mejorar así los tiempos de procesado.

Aplicando el Código de Matlab *CV\_map* a éstas imágenes se obtienen **imágenes georreferenciadas en formato TIFF, con resolución de 10 metros y con un error en la estimación de biomasa de 7.76 toneladas por pixel**

Se aplicó dicho código 2 veces a cada imagen: una con la máquina de monte bravo y otra con la máquina de latizal fustal, por lo tanto de cada imagen obtenemos 2 imágenes de biomasa distinta, uno con valores para monte bravo y el otro para valores de latizal-fustal (tabla 16)

**Tabla 16. Imágenes generadas**

Imágenes Sentinel 2	
Entrada	Salida
TYL	TYL_monte_bravo
	TYL_latizal_fustal
SXH	SXH_monte_bravo
	SXH_latizal_fustal
SXJ	SXJ_monte_bravo
	SXJ_latizal_fustal
SYH	SYH_monte_bravo
	SYH_latizal_fustal
SYJ	SYJ_monte_bravo
	SYJ_latizal_fustal
TXK	TXK_monte_bravo
	TXK_latizal_fustal
TYK	TYK_monte_bravo
	TYK_latizal_fustal

Después combinando estas imágenes y aplicando la segmentación SIG (Anejo 11) se obtienen los mapas finales del proyecto (7.Cartografía generada)

Gracias a estos mapas se calcularon las toneladas de biomasa, el stock de carbono y el CO<sub>2</sub> retenido en las masas de *Pinus halepensis* (tabla 17):

**Tabla 17. Resumen cálculos realizados**

DATOS DE INTERES PARA LOS MONTES DE <i>Pinus halepensis</i>	
BIOMASA	<b>21.496.334,56 toneladas</b>
STOCK DE CARBONO	<b>10.649.284,14 toneladas</b>
CO <sub>2</sub> RETENIDO	<b>39.082.872,79 toneladas</b>

## 6.2 DISCUSIÓN

Los resultados de este proyecto son dos mapas de biomasa y dos de stock de carbono de la Comunidad Valenciana, obtenidos a partir de las máquinas entrenadas por procesos gaussianos.

Se escoge este método ya que la reflectividad y la biomasa no están relacionadas linealmente por lo que es necesario un modelo de regresión no lineal. En este caso por procesos gaussianos con modelo exponencial, que encuentre una relación entre los datos.

Los mapas obtenidos tienen un error general de 7,76 toneladas por hectárea, teniendo en cuenta que la cantidad media de las parcelas es de 46 toneladas por hectárea, el error que se comete es del orden del 16%, error asumible para una correcta gestión forestal, además dicho error es, dado la rapidez del método y el coste del mismo, más que adecuado.

En cuanto a este error, tiene un bias (sesgo) cercano a 0, esto significa que el error está repartido a ambos lados de la recta de pendiente 1 de la regresión.

Los algoritmos se han aplicado según una segmentación del año 2007 por lo que si en éstos años el monte ha cambiado de estructura, el valor obtenido de la biomasa no sería válido.

Teniendo en cuenta que no se tiene previsto por el momento la realización del 4º Inventario Forestal Nacional según la Dirección General de Desarrollo rural Innovación y Política Forestal (Anejo 12), éstos son los datos con los que se puede trabajar.

En cuanto a las bandas de las imágenes Sentinel 2 se puede observar que no es necesario el uso de todas ellas en el algoritmo de regresión, sino que simplemente utilizando una combinación de ellas (rojo + banda 8) para el NDVI y la banda 8A es posible obtener una muy buena estimación de la biomasa.

El uso de datos LiDAR conlleva una mejora del modelo pero dado la extensión de proyecto no es viable su procesado con los recursos informáticos disponibles.

A partir del mapa de biomasa es posible la generación del mapa de stock de carbono



en los bosques de *Pinus halepensis* en la Comunidad Valenciana. Además, a partir de este último, es posible el cálculo del CO<sub>2</sub> retenido en nuestros bosques. El cálculo de CO<sub>2</sub> retenido nos dice cuánta cantidad de éste elemento sería emitido a la atmosfera en caso de Incendio Forestal.



## 7. CARTOGRAFÍA GENERADA

## 8. CONCLUSIONES

La teledetección nos proporciona datos, directos (reflectividades) o indirectos (índices) de una manera rápida, sencilla y eficaz. Como se ha podido comprobar la generación de mapas de biomasa con un error aceptable para el ámbito de la gestión forestal a partir de la teledetección es posible.

La metodología propuesta simplifica las labores de campo ya que no es necesario inventariar un gran número de parcelas para el cálculo de la biomasa, ahorrando así costes. La teledetección se presenta pues como una herramienta útil y eficaz para el cálculo de la biomasa.

A parte de imágenes satélite podemos encontrar otro tipo de datos obtenidos a partir de teledetección como por ejemplo los datos LiDAR, que introducen la variable tridimensional, estos datos en nuestro caso mejoran el modelo pero no de una manera significativa. Debido a la extensión del proyecto es más útil el uso únicamente reflectividades de las imágenes Sentinel 2.

Los mapas generados se pueden combinar con otras capas cartográficas para diferentes análisis SIG.

La replicación del método en otra época permitirá el estudio de la evolución de la biomasa en las zonas de *Pinus halepensis*.

Utilizando las ecuaciones alométricas de otro tipo de especie, se pueden calcular mapas de biomasa para dicha especie.

El modelo propuesto en éste proyecto es rápido y asequible, pero también mejorable.

### 8.1 Perspectivas futuras

Éste trabajo abre toda una línea de investigación para la mejora del modelo de cálculo de biomasa, desde la introducción de nuevas variables como índices de vegetación como por ejemplo el LAI (Índice de área foliar) o el FAPAR (fracción de radiación fotosintéticamente activa absorbida por las plantas), o la segmentación por zonas climáticas (Anejo 13), hasta la invención de nuevos parámetros para la segmentación de la parcelas a partir de los inventarios forestales nacionales. (Investigación en curso).

Se ha comenzado el estudio de los inventarios forestales de referencia (IFN3) y se ha ideado una herramienta para cálculo de biomasa total y por fracciones, así como otras variables dendrométricas y dasométricas, a partir de parcelas del inventario forestal nacional y la tabla de árboles del mismo (Anejo 14). Esta herramienta minimiza el tiempo de cálculo de la biomasa, de hacerlo de manera manual (4 horas para el caso de 32 parcelas a 18 segundos, llegando incluso a poder calcular la biomasa de 1100 parcelas en 43 segundos).

Mediante esta herramienta y añadiendo nuevas variables de entradas así como un nuevo sistema de clasificación de los montes, se pretende mejorar el modelo obtenido en este proyecto.

La investigación propuesta se llevara a cabo en el grupo de investigación ICTvsC.

## 9. PRESUPUESTO

A partir de la fórmula

$$PGC = PEM + GG + BI$$

Dónde:

PGC: Presupuesto General por Contrata

PEM: Presupuesto de Ejecución Material

GG: Gastos Generales

BI: Beneficio Industrial

Se va proceder al cálculo del presupuesto general del proyecto, teniendo en cuenta las siguientes consideraciones:

- El presupuesto de ejecución material y los gastos materiales incluyen: todos los materiales, personal y equipos técnicos que se hayan podido emplear durante el transcurso del proyecto.
- Los gastos generales se refieren a los gastos externos derivados de la actividad tales como agua, luz o limpieza, por ejemplo.
- El porcentaje aplicado para el cálculo de los gastos generales será del 13 % según BOE del 20 abril de 2018.
- El Beneficio Industrial será del 6 %

Teniendo en cuenta las consideraciones anteriores se pasa al cálculo del presupuesto del proyecto.

### 9.1 Mano de Obra

Para la ejecución del presente proyecto ha sido necesario la cooperación de dos ingenieros, ambos con el mismo sueldo, cuyo salario base es de 60.45 euros al día más un plus de convenio de 7.86 al día, además de la parte proporcional de las pagas extras, Por lo tanto éstos técnicos tendrán una base de cotización de 2351.55 € (tabla 18)

**Tabla 18. Gasto empresarial de un trabajador**

	cuantía €	días	Total €
<b>salario base</b>	60.45	30	1813.5
<b>plus convenio</b>	7.86	30	235.8
<b>paga verano</b>			151.125
<b>paga navidad</b>			151.125
<b>total</b>			<b>2.351,55</b>

De esta base se calcularán las cotizaciones a la seguridad social tanto para la empresa como para el trabajador (tabla 19)

**Tabla 19. Cotizaciones**

TRABAJADOR		EMPRESA	
<b>base imponible</b>		<b>2351.55 €</b>	
<b>Comunes (4.7%)</b>	110.52285	<b>Comunes (23.6%)</b>	554.9658
<b>Formación (0.1%)</b>	2.35155	<b>AT y EP (1.65%)</b>	38.800575
<b>Desempleo (1.6%)</b>	37.6248	<b>Desempleo (6.7%)</b>	157.55385
<b>IRPF (14.13%)</b>	332.274015	<b>FP (0.6%)</b>	14.1093
		<b>FGS (0.2%)</b>	4.7031
<b>TOTAL</b>	<b>482.77 €</b>	<b>TOTAL</b>	<b>770.13 €</b>

Por lo tanto el gasto empresarial de cada uno de los trabajadores será de:

$$2351.55 + 770.13 = 3121.68 \text{ €/mes}$$

Teniendo en cuenta que un trabajador trabaja una media de 164 horas al mes el precio a la hora sería el siguiente:

Precio trabajador por hora: 19.03 €/h

Como ambos trabajadores tienen el mismo coste se computan las horas de ambos conjuntamente según las fases del proyecto (tabla 20)

**Tabla 20. Precio Mano de obra por subfases**

FASE	TAREA	Técnicos (horas)	Precio unitario €	total €
<b>1</b>	Generación de la base de datos del entrenamiento			
<b>1.1</b>	Datos de campo, cálculos en oficina	120	19.03	2283.6
<b>1.2</b>	Descarga y procesado de datos LiDAR	70	19.03	1332.1
<b>1.3</b>	Descarga y procesado de Sentinel-2	70	19.03	1332.1
<b>2</b>	Entrenamiento y validación de los procesos Gaussianos			
<b>2.1</b>	Entrenamiento	80	19.03	1522.4
<b>2.2</b>	Validación	80	19.03	1522.4
<b>3</b>	Aplicación de las máquinas entrenadas y Generación de Mapas de Biomasa			
<b>3.1</b>	Aplicación máquinas entrenadas	64	19.03	1217.92
<b>3.2</b>	Generación de los mapas de Biomasa	64	19.03	1217.92
<b>4</b>	Extensión del modelo a la comunidad Valenciana			
<b>4.1</b>	Descarga y procesado de imágenes Sentinel	80	19.03	1522.4
<b>4.2</b>	Aplicación de máquinas entrenadas y generación de imágenes de Biomasa	48	19.03	913.44
<b>4.3</b>	Segmentación y generación de mapa de biomasa.	28	19.03	532.84
<b>5</b>	Generación del mapa de Stock de Carbono			
<b>6</b>	Cuantificación CO <sub>2</sub> retenido			
	<b>total</b>	<b>736</b>		<b>14.006,08</b>

Que en total por fases (tabla 21)

**Tabla 21. Precio de mano de obra por fases**

FASE	TAREA	subtotal fases €
1	Generación de la base de datos del entrenamiento	4947.8
2	Entrenamiento y validación de los procesos Gaussianos	3044.8
3	Aplicación de las máquinas entrenadas y Generación de Mapas de Biomasa	2435.84
4	Extensión del modelo a la comunidad Valenciana	2968.68
5	Generación del mapa de Stock de Carbono	380.6
6	Cuantificación CO <sub>2</sub> retenido	228.36
<b>Total</b>		<b>14.006,08</b>

## 9.2 Materiales y Software

Los materiales y software utilizados en el éste proyecto han sido (tabla 22 y 23)

**Tabla 22. Software empleado**

Software	Precio licencia anual €
Arcgis	5500
Envi +IDL	250
Matlab	800

**Tabla 23. Materiales empleados**

Material	Precio €	precio sin IVA €	cuota de amortización (4 años) €	porcentaje de amortización	amortización anual €	amortización mensual €
Distanciómetro Laser	400	316	79	25	19.75	1.64
Forcípula	70	55.3	13.82	25	3.45	0.28
GPS Garmin	130	102.7	25.67	25	6.41	0.53
HP Notebook	900	711	177.75	25	44.43	3.70

Se considera el periodo mínimo de licencia de Software de 1 año y con respecto al material, no ha sido necesaria su compra ya que se disponía de él por lo que se calculará la amortización en 4 años, se determina el periodo mínimo de amortización en 1 mes.

Teniendo en cuenta que el trabajo en sí ha tenido una duración de 736 horas que son en total 92 días laborables, en total la duración del trabajo ha sido de 18.4 semanas, es decir, 4.6 meses que a efectos de cálculos, los tomamos como 5 meses (tabla 24)

Por lo tanto:

**Tabla 24. Total materiales y software**

Software	Amortización €	meses	Total €
Arcgis			5500
Envi +IDL			250
Matlab			800
Material			
Distanciómetro Laser	1.64	5	8.2
Forcípula	0.28	5	1.4
GPS Garmin	0.53	5	2.65
HP Notebook	3.7	5	18.5
<b>Total</b>			<b>6.580,75</b>

### 9.3 Presupuesto de Ejecución Material

Por lo tanto el presupuesto de ejecución material es de (tabla 25)

**Tabla 25. Presupuesto de ejecución material**

Concepto	Precio €
Mano de obra	<b>14006.08</b>
Materiales y software	<b>6580.75</b>
<b>Total</b>	<b>20.586,83</b>

### 9.4 Presupuesto General

El montante del proyecto asciende a (tabla 26)

**Tabla 26. Presupuesto General**

Presupuesto General	%	Total €
<b>Presupuesto ejecución material</b>		<b>20586.83</b>
<b>Gastos generales</b>	<b>13</b>	<b>2676.28</b>
<b>Beneficio Industrial</b>	<b>6</b>	<b>1235.20</b>
<b>TOTAL</b>		<b>24.498,32</b>

## 10. BIBLIOGRAFIA

- Ali, I., Greifeneder, F., Stamenkovic, J., Neumann, M., & Notarnicola, C. (2015). "Review of Machine Learning Approaches for Biomass and Soil Moisture Retrievals from Remote Sensing Data". *Remote Sensing*, 7, 16398-16421.
- Atlas Forestal de Castilla y León  
<[https://medioambiente.jcyl.es/web/jcyl/MedioAmbiente/es/Plantilla100Detalle/1284211844539/\\_/1284204012545/Redaccion](https://medioambiente.jcyl.es/web/jcyl/MedioAmbiente/es/Plantilla100Detalle/1284211844539/_/1284204012545/Redaccion)> [Consulta: 02 julio de 2019]
- Azong Cho, M., Skidmore, A., Corsi, F., van Wieren, S., & Sobhan, I. (2007). "Estimation of green/herb biomass from airborne hyperspectral imagery using spectral indices and partial least squares regression". *International Journal of Applied Earth Observation and Geoinformation*, 9, 414-424
- Blackburn, G.A. (1998). "Quantifying chlorophylls and carotenoids at leaf and canopy scales; an evaluation of some hyperspectral approaches". *Remote Sensing of Environment*, 6, 273-285
- Broge, N.H., & Mortensen, J.V. (2002). "Deriving green crop area index and canopy chlorophyll density of winter wheat from spectral reflectance data". *Remote Sensing of Environment*, 81, 45-57
- Cáceres, J., Pilar Martín, M., & Salas, J. (2015). "Análisis temporal de biomasa y stocks de carbono en un ecosistema de dehesa mediante imágenes Landsat, y su relación con factores climáticos". *Ciencias Espaciales*, 8(1), 190-211.  
<https://doi.org/10.5377/ce.v8i1.2049>
- Camps-Valls, G., Bruzzone, L. (Eds.), 2009. "Kernel Methods for Remote Sensing Data Analysis". Wiley & Sons, UK
- Camps-Valls, Verrelst, Munoz-Mari, Laparra, Mateo-Jimenez, & Gomez-Dans. (2016). "A Survey on Gaussian Processes for Earth-Observation Data Analysis: A Comprehensive Investigation". *IEEE Geoscience and Remote Sensing Magazine*. Retrieved from [http://discovery.ucl.ac.uk/1500607/1/Gomez-Dans\\_main\\_r1.pdf](http://discovery.ucl.ac.uk/1500607/1/Gomez-Dans_main_r1.pdf) [Consulta 12 Marzo 2019]
- Centro de descargas del Cnig.  
<<http://centrodedescargas.cnig.es/CentroDescargas/index.jsp>> [Consulta: 05 julio 2019]
- Edirisinghe, A., Clark, D., & Waugh, D. (2012). "Spatio-temporal modelling of bio-mass of intensively grazed perennial dairy pastures using multispectral remote sensing". *International Journal of Applied Earth Observation and Geoinformation*, 16, 5-16
- Fuster, B. (2017) *Comparación de métodos de aprendizaje automático para la estimación de parámetros biofísicos sobre cultivos específicos y genéricos a partir de imágenes de satélite landsat-8*. Trabajo Final de Master. Valencia: Escuela Técnica Superior de Ingenieros de Telecomunicación de la Universitat Politècnica de València,

- García, M., Riaño, D., Chuvieco, E., & Danson, F.M. (2010). "Estimating biomass carbon stocks for a Mediterranean forest in central Spain using LiDAR height and intensity data". *Remote Sensing of Environment*, 114, 816-830
- Georgia Galidaki, Dimitris Zianis, Ioannis Gitas, Kalliopi Radoglou, Vassilia Karathanassi, Maria Tsakiri-Strati, Iain Woodhouse & Giorgos Mallinis (2017) "Vegetation biomass estimation with remote sensing: focus on forest and other wooded land over the Mediterranean ecosystem", *International Journal of Remote Sensing*, 38:7, 1940-1966,
- Hansen, P.M., & Schjoerring, J.K. (2003). "Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression". *Remote Sensing of Environment*, 86, 542-553
- Martin, M.E., Plourde, L.C., Ollinger, S.V., Smith, M.L., & McNeil, B. (2008). "A generalizable method for remote sensing of canopy nitrogen across a wide range of forest ecosystems". *Remote Sensing of Environment*, 12, 3511-3519
- Meng, Q., Cieszewski, C., Madden, M., & Borders, B. (2007). "A linear mixed-effects model of biomass and volume of trees using Landsat ETM+ images". *Forest Ecology and Management*, 244, 93-101
- Ministerio de transición ecológica.< <https://www.miteco.gob.es/es/>>[Consulta : 25 junio 2019]
- Muukkonen, P., & Heiskanen, J. (2007). "Biomass estimation over a large area based on standwise forest inventory data and ASTER and MODIS satellite data: A possibility to verify carbon inventories". *Remote Sensing of Environment*, 107, 617-624
- Næsset, E. (2002). "Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data". *Remote Sensing of Environment*, 80(1), 88-99. [https://doi.org/10.1016/S0034-4257\(01\)00290-5](https://doi.org/10.1016/S0034-4257(01)00290-5) [Consulta 18 Junio 2019]
- Neal, R. M, 1996" Bayesian Learning for Neuronal Networks", number 118 in *Lecture Notes in Statistics*, Springer, New York.
- Página de la ESA <(https://Sentinels.copernicus.eu/web/Sentinel/news-/article/upcoming-Sentinel-2-level-2a-product-evolution)> [Consulta: 25 Junio 2019]
- Página Descargas de la Agencia Espacial Europea < <https://scihub.copernicus.eu/dhus/> >[Consulta: 15 Abril 2019]
- Parresol, B.R. (1999). "Assessing tree and stand biomass: A review with examples and critical comparisons". *Forest Science* 45(4), 573-593.
- Rasmussen, C.E., Williams, C.K.I., 2006. "Gaussian Processes for Machine Learning". *The MIT Press*, New York, US.
- Ruiz-Peinado, R., Río, M. del, Montero, G. (2011). "New models for estimating the

carbon sink capacity of Spanish softwood species". *Forest Systems* 20, 176-188.

Sánchez Camperos, E. N., Alanís García, A. Y., & Ingebook. (2006). *Redes neuronales: conceptos fundamentales y aplicaciones a control automático*. Madrid: Pearson Educación.

Todd, S.W., Hoffer, R.M., & Milchunas, D.G. (1998). "Biomass estimation on grazed and ungrazed rangelands using spectral indices". *International Journal of Remote Sensing*, 19, 427-438

Verrelst, J., Muñoz, J., Alonso, L., Delegido, J., Rivera, J., Camps-Valls, G., Moreno, J., 2012a. "Machine learning regression algorithms for biophysical parameter retrieval: opportunities for Sentinel-2 and -3". *Remote Sensing of Environment* 118, 127-139

Verrelst, Rivera, Gitelson, Delegido, Moreno, & Camps-Valls. (2016). "Spectral band selection for vegetation properties retrieval using Gaussian processes regression". *International Journal of Applied Earth Observations and Geoinformation*, 52(C), 554-567.

Vinué-Visús, D., Oliver-Villanueva, J.V., Coll-Aliaga, E.P., Camacho, F. (2019). "Estimación de la biomasa total de *Pinus halepensis* Mill. con imágenes Sentinel-2 y máquinas de aprendizaje automático en un contexto de cambio climático". *En Comunicaciones del III Congreso Forestal de la Comunidad Valenciana*. Calpe (España), 15 y 16 de noviembre de 2018. Ed. Universitat de València. Valencia, España. 244 pp.



## ANEJOS



## ANEJO 1. Tabla resumen Inventario de campo











## ANEJO 2. Base de datos de campo

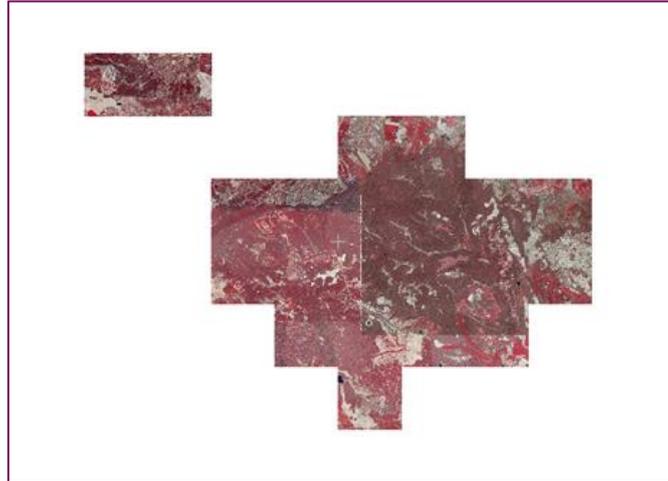




### ANEJO 3. Procesado Información LiDAR

Para el tratamiento de los datos LiDAR y obtener los estadísticos de la nube de puntos se han realizado los siguientes pasos:

1. Unión de todas las nubes de puntos de la zona de estudio con LasMerge (LASTools)(Figura 14)



**Figura 14. LasMerge de LASTools**

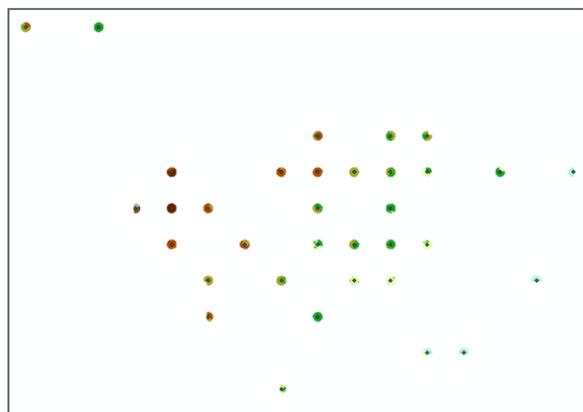
2. Corte de la nube de puntos con un buffer de 15metros (radio de la parcela) y con la capa zona de halepensis (FUSION)(Figura 15)

Tiempo de procesado: Con el buffer de 15 metros (92 segundos):

```
C:\FUSION\polyclipdata C:\Users\silvi\Desktop\PROYECTO\BUFFER_4_30.shp  
C:\Users\silvia\Desktop\PROYECTO\LIDAR\ZONA4\COMPLETO\zona_4v_buffer.las  
C:\Users\silvia\Desktop\PROYECTO\LIDAR\ZONA4\COMPLETO\viejo4me.las
```

Tiempo de procesado: Con zona de halepensis (5seg):

```
C:\FUSION\polyclipdata C:\Users\silvi\Desktop\PROYECTO\HALEPENSIS_SEGMENTACION.shp  
C:\Users\silvia\Desktop\PROYECTO\LIDAR\ZONA4\COMPLETO\zona_4v_bruta.las  
C:\Users\silvia\Desktop\PROYECTO\LIDAR\ZONA4\COMPLETO\zona_4v_buffer.las
```

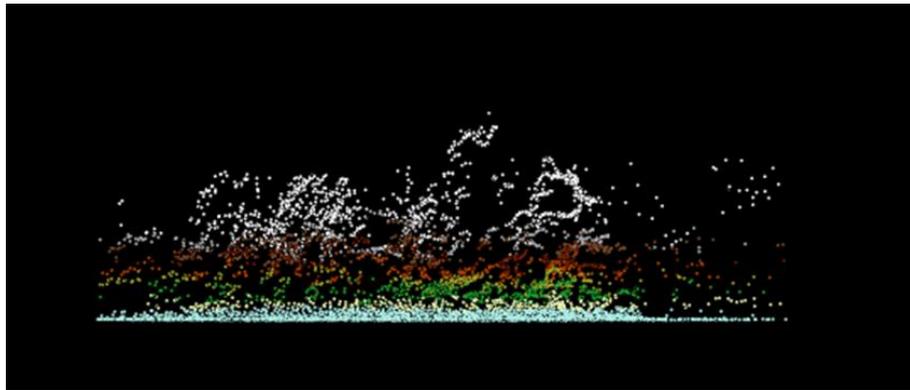


**Figura 15. Recorte de la nube de puntos**

3. Limpieza de la nube de puntos, Noise filter con tolerancia de 0.05 ( CLOUD COMPARE)

En caso de que queden outlayers, usar el comando Clip data (FUSION)

4. División del fichero en parcelas con Poly Clip Data (FUSION)
5. Eliminación de puntos dobles (mismas coordenadas X,Y,Z) con LasDuplicate (LasTools)
6. Clasificación de la nube de puntos en Suelo- No Suelo con LASGROUND\_NEW. Normalización a cota 0(LasTools) (Figura 16)



**Figura 16. Normalización de la nube de puntos**

7. Computación de alturas y separación con LASHEIGHT (LasTools)

Con la herramienta lasheight se toma la nube de puntos de una zona y se sustituye la altitud por la altura. Además esta herramienta permite reclasificar los puntos.

Eliminamos los puntos con alturas por debajo de -0.2 (precisión del LiDAR)

- -0.2 a 0.2 clasificar como suelo.
- 0.2 a 1.5 low vegetation
- 1.5 a 5 medium vegetation
- 5 a 100 height vegetation

Así se consigue una nube con cota 0 donde se pueden consultar las alturas sobre nivel del suelo.

8. Calculo de los estadísticos con CLOUDMETRICS de FUSION

```
C:\Fusion\CloudMetrics /above:0.1/new /first /minht:0.1  
C:\Users\silvia\Desktop\EOLAB\LIDAR_AEREO_ENGUERA\CLAS\ENGUERA_000021_DUPLI_GROUND_CLAS.la  
s C:\Users\silvia\Desktop\EOLAB\LIDAR_AEREO_ENGUERA\CLAS\VAR21.txt
```



#### ANEJO 4. Tabla estadísticos LiDAR

















## ANEJO 5. Procesado Sentinel 2

## Adquisición y tipo de Imágenes Sentinel 2

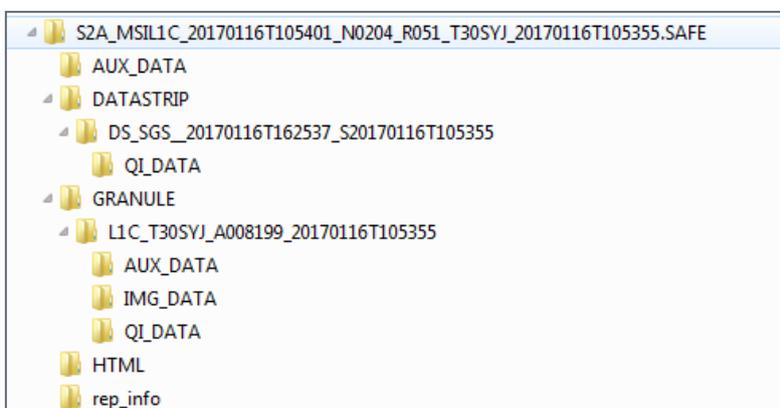
Las imágenes de Sentinel-2 se pueden obtener, previo registro del usuario, desde:

\* <https://scihub.copernicus.eu/dhus/>, de la Agencia Espacial Europea

\* <http://earthexplorer.usgs.gov/> del USGS (United States Geological Survey)

Las imágenes Sentinel-2 se encuentran en formato L1C, con valores de reflectividad TOA (Top Of Atmosphere) sin corrección atmosférica o L2A, con esta corrección. Las imágenes L2A desde el servidor se encuentran a partir de mayo de 2016, aproximadamente. Las correspondientes a fechas anteriores deben ser procesadas. La corrección se realiza en base a los metadatos incluidos en las carpetas de la imagen, pero las imágenes obtenidas desde el servidor USGS no los contienen, por los que no pueden ser corregidas atmosféricamente de forma automática.

El archivo obtenido desde SCIHUB viene comprimido y en formato SAFE. La descarga se estructura en varias carpetas (figura 17, nivel L1C).



**Figura 17. Estructura de datos de imágenes Sentinel 2A en nivel L1C**

En la carpeta GRANULE se encuentra la escena identificada por un código de dos cifras y tres letras (zona UTM). La descarga contiene otros datos auxiliares y bandas de calidad. Toda esta información, se utiliza para el procesado hasta el nivel L2A.

La lectura de las imágenes se puede realizar de varias formas:

- añadiendo directamente el archivo comprimido a SNAP, software de la ESA;
- importando las imágenes .jp2 en ENVI (aunque no estarán georreferenciadas).

## Corrección atmosférica

Como ya hemos dicho, las imágenes con un nivel de procesamiento L1C deben ser corregidas atmosféricamente, este paso, se puede realizar de diversas maneras con SNAP-SEN2COR o directamente a partir de línea de comandos en símbolo del sistema (CMD) (Figura 18)

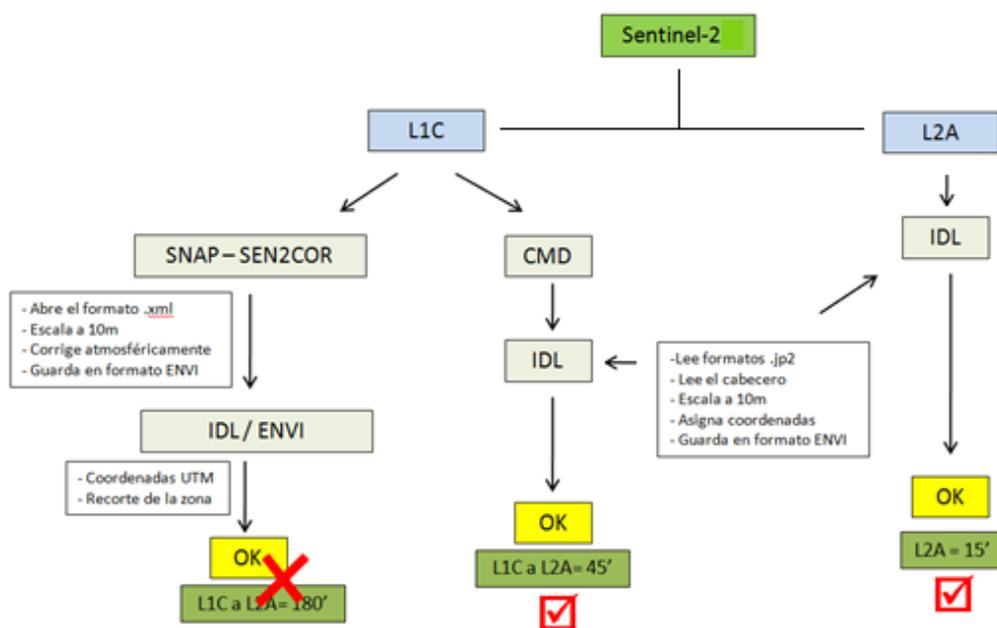


Figura 18. Procedimientos para el procesado de Sentinel-2. Fuente: David Vinué Visús

**SNAP-SEN2COR**

Para realizar la corrección atmosférica de las imágenes Sentinel-2 es necesario incluir toda la información en SNAP, archivos .xml y accesorios, y no solo los archivos .jp2. La imagen se incluye en SNAP mediante la importación:

File - Import -Optical Sensors-Sentinel2 - S2A-MS1 L1C (Seleccionar el archivo \*.xml)

Las imágenes siempre aparecen en su referencia UTM, por lo que las coordenadas son homogéneas para todas las fechas, y con el mismo número de píxeles según la resolución espacial de cada banda (tabla 15):

Tabla 15. Píxeles de la imagen según la resolución espacial.

m	Píxeles
10	10980*10980
20	5490*5490
60	1830*1830

Se puede elegir entre usar las resoluciones de cada banda u homogeneizarlas a una única resolución espacial, cambiando el tamaño del píxel pero manteniendo la resolución original.

La acción de SEN2COR se encuentra en: Optical-Thematical Land Processing-SEN2COR

Para el procesado simplemente se selecciona el archivo y se indican los parámetros de procesado. Indicar aquí la resolución de 10 m. La carpeta con la imagen corregida se genera por defecto en la misma ubicación que la original.

### CMD. PROCESADO POR LINEA DE COMANDO

Las imágenes Sentinel-2B están disponibles en nivel operativo desde noviembre de 2017. El nivel pre-operativo se desactivó en esas mismas fechas. Sin embargo, SNAP no reconoce la extensión 2B, por lo que se puede realizar el procesado hasta L2A directamente por la línea de comandos ("cmd").

Para ello es necesario:

1- cambiar el nombre de la carpeta que contiene la imagen S2B, y renombrarla como S2A;

2- desde la ubicación misma de "cmd", indicar el procesado, la ruta y la resolución:

```
L2A_Process  
C:\Users\eolab\Desktop\ENGUERA\S2A_MSIL1C_20171107T105229_N0206_R051_T30SXJ  
_20171107T131035.SAFE --resolution=10
```

### Procesado con IDL

Los análisis de las bandas se realizarán en una misma resolución espacial, lo que además facilitará su visualizado en ENVI.

\*\* Si la imagen se procesa en SNAP se realiza un "resampling", esto es, se modifica el tamaño de los píxeles de todas las bandas a una misma resolución (raster/resampling). Idóneamente se transforma a 10 m (resolución de la banda B2 y 10980 píxeles). Se guarda en formato "ENVI".

\*\* Si la imagen se procesa por la línea de comandos, este proceso no se realiza.

### Manejo de las carpetas

Las imágenes procesadas a nivel L2A se guardan como formato jpg2000 en sucesivas carpetas, divididas por resolución. Para poder trabajar con IDL es necesario que creamos una nueva carpeta que se llame S2\_ (FECHA DE TOMA DE SENTINEL) que contenga las siguientes bandas:

- De resolución de 10 metros: 2,3,4,8,TCI
- De resolución de 20 metros: 5,6,7,8<sup>a</sup>,11,12,SCL + MSK\_CLDPRB\_20m +MSK\_SNWPRB\_20m
- Archivo MDL\_TL en formato txt

Se utiliza el código CABECERO\_S2 Y PROCESADO\_S2

Se cambian los datos necesarios para la correcta lectura de las imágenes (fecha, rutas



y nombres) y en el caso de querer recortarla se añade centro y amplitud de la zona de recorte.

Una vez ejecutado y finalizado el programa, se genera una imagen total. Georreferenciada, con todas las bandas, incluido el ángulo solar leído en el cabecero, el NDVI y otra imagen recortada sobre la zona de estudio (si ha sido el caso)

Para la extracción de reflectividades, se empleará el código de IDL, EXTRACTOR\_S2. Que extrae el valor de los píxeles de las parcelas de estudio, para añadir estos datos a la base de datos.



## ANEJO 6. Códigos IDL empleados

**CÓDIGO PROCESADO\_S2 y CABECERO\_S2****PRO PROCESADO\_S2;**

```
; PREPARACIÓN DE LAS IMÁGENES PARA EL PROCESADO POR MEDIO DE "GAUSSIAN  
PROCESS"  
  
; TAREA (1) "LECTURA DE LOS CABECEROS"  
;TAREA (2) "LECTURA DE LAS BANDAS .JP2"  
;TAREA (3) "VALORES DE LA ZONA 0"  
;TAREA (4) "REESCALADO DE LAS BANDAS A 10m"  
;TAREA (5) "CREACIÓN DE LA BANDA DEL ÁNGULO SOLAR"  
;TAREA (6) "CREACIÓN DE LA BANDA NDVI"  
;TAREA (7) "DEFINICIÓN DE LAS MÁSCARAS"  
;TAREA (8) "ESCRITURA DE LA IMAGEN L2A"  
;TAREA (9) "ESCRITURA DE LA IMAGEN L2A - ZONA 0"  
  
;(Cronómetro)  
T=system(1)  
  
fecha='20170705'  
code='T105031'  
satelite='2A'  
  
; *** ¿APLICAMOS MÁSCARAS? ***  
; SÍ=1 / NO=0  
clasificada=0  
  
; *** ENTRADAS ***  
pathin='C:\Users\silvi\Desktop\EOLAB\SENTINEL CV\S2_'+fecha+'\  
pathout='C:\Users\silvi\Desktop\EOLAB\SENTINEL CV\  
  
imagen=pathin+'L2A_T30TXK_'+fecha+code  
cabecero1=pathin+'MTD_TL.txt'  
  
; *** SALIDAS ***  
; nombre de los archivos  
titulo='S2_'+fecha  
  
; *** PARÁMETROS DE SALIDA ***  
sensor='Sentinel'+satelite+'-L2A'  
nbands=13  
order=0  
type=4  
interleave='bsq'  
  
;*****  
; TAREA 1 - LECTURA DE LAS VARIABLES DE LOS CABECEROS ORIGINALES  
;*****  
openr, lun, cabecero1, /get_lun  
DATO1 = ''  
for i=0,28 do readf, lun, DATO1  
  for i=29,30 do BEGIN  
    DATO1 = ''  
    readf, lun, DATO1  
    CADENA11=strsplit(DATO1, '>', /EXTRACT)  
    CADENA12=strsplit(CADENA11(1), '</', /EXTRACT)  
    if CADENA12 (1) eq 'ULX' then begin  
      lon =long(float(CADENA12(0)))  
    endif  
    if CADENA12 (1) eq 'ULY' then begin  
      lat =long(float(CADENA12(0)))  
    endif  
  endfor  
;Lectura del archivo cabecero MDL_txt  
openr, lun, cabecero1, /get_lun  
DATO1 = ''
```

```
for j=0,108 do readf,lun,DAT01
  for j=109,109 do begin
    DAT01 = ''
    readf,lun,DAT01
    CADENA13=strsplit(DAT01,'<ZENITH_ANGLE unit=""/>', /EXTRACT)
    if CADENA13 (0) eq 'deg' then begin
      zenith =float(CADENA13(1))
    endif
  endfor

openr,lun,cabecerol,/get_lun
DATO2 = ''
for k=0,13 do readf,lun,DAT01
  for k=14,14 do begin
    DATO2 = ''
    readf,lun,DAT01
    CADENA14=strsplit(DAT01,'<HORIZONTAL_CS_NAME> /WGS UTM zone N', /EXTRACT)
    if CADENA14 (0) eq '84' then begin
      UTM =fix(CADENA14(1))
    endif
  endfor

print,'DATOS DE LA IMAGEN'
print,' *CORNER_UL_PROJECTION_X_PRODUCT =',lon
print,' *CORNER_UL_PROJECTION_Y_PRODUCT =',lat
print,' *ZONA UTM =',UTM
print,' *ÁNGULO ZENITAL =',zenith

print,'TAREA (1) "LECTURA DE LOS CABECEROS": ¡HECHO!'

;*****
; TAREA 2 - USO DE "READ_JPEG2000" PARA ABRIR LOS ORIGINALES
;*****
banda2B=imagen+'_B02_10m.jp2' ; 0.440-0.538 - OLI2
banda3G=imagen+'_B03_10m.jp2' ; 0.537-0.582 - OLI3
banda4R=imagen+'_B04_10m.jp2' ; 0.646-0.684 - OLI4
banda5RE1=imagen+'_B05_20m.jp2' ; 0.694-0.713
banda6RE2=imagen+'_B06_20m.jp2' ; 0.731-0.749
banda7RE3=imagen+'_B07_20m.jp2' ; 0.769-0.797
banda8NIR=imagen+'_B08_10m.jp2' ; 0.760-0.908
banda8ANIR=imagen+'_B8A_20m.jp2' ; 0.848-0.881 - OLI5
banda11SWIR1=imagen+'_B11_20m.jp2' ; 1.539-1.682 - OLI6
banda12SWIR2=imagen+'_B12_20m.jp2' ; 2.078-2.320 - OLI7

file_banda2B=read_jpeg2000(banda2B)
print,'BANDA 2 LEIDA'
file_banda3G=read_jpeg2000(banda3G)
print,'BANDA 3 LEIDA'
file_banda4R=read_jpeg2000(banda4R)
print,'BANDA 4 LEIDA'
file_banda5RE1=read_jpeg2000(banda5RE1)
print,'BANDA 5 LEIDA'
file_banda6RE2=read_jpeg2000(banda6RE2)
print,'BANDA 6 LEIDA'
file_banda7RE3=read_jpeg2000(banda7RE3)
print,'BANDA 7 LEIDA'
file_banda8NIR=read_jpeg2000(banda8NIR)
print,'BANDA 8 LEIDA'
file_banda8ANIR=read_jpeg2000(banda8ANIR)
print,'BANDA 8A LEIDA'
file_banda11SWIR1=read_jpeg2000(banda11SWIR1)
print,'BANDA 11 LEIDA'
file_banda12SWIR2=read_jpeg2000(banda12SWIR2)
print,'BANDA 12 LEIDA'

A=SIZE(file_banda3G)
```

```
col10=A(1)
row10=A(2)
```

```
B=SIZE(file_banda8ANIR)
col20=B(1)
row20=B(2)
```

```
print, 'Banda 3= ', col10
print, 'Banda 8A= ', col20
```

```
print, 'TAREA (2) "LECTURA DE LAS IMÁGENES .JP2":;HECHO!'
```

```
;*****
; TAREA 3: CÁLCULO DE LAS VARIABLES PARA EL RECORTE DE LA ZONA 0
;*****
; PARA EL RECORTE DE UNA ZONA, INDICAR AQUÍ LOS PARÁMETROS DEL RECORTE
; *** INDICAR LA AMPLITUD DEL RECORTE DE LA ZONA DE ESTUDIO EN PÍXELES ***
; zona de recorte
;X='10X10'
; Tamaño del pixel
p=10d
; Tamaño del recorte (genera píxeles impares para tener un centro perfecto)
;area=10000
;col0=(area-p)/p
;row0=col0

;;centro_lon=699475d
;;centro_lat=4401705d

; *** AMPLITUD DEL RECORTE DE LA ZONA DE ESTUDIO EN METROS ***
;;ext=col0*p
;EXTENSIÓN DE LA PARCELA en píxeles
;;radio=fix(col0-1)/2
;EXTENSIÓN DE LA PARCELA en metros
;;radio_m=ext/2

; *** VALORES PARA EL RECORTE ***
;centro_lon_pixel=abs((centro_lon-lon)/p)
;centro_lat_pixel=abs(((centro_lat-lat)/p))
;centro_lon_pixel=fix((centro_lon_pixel))
;centro_lat_pixel=fix((centro_lat_pixel))

; PIXEL SUPERIOR IZQUIERDO, REFERENCIA DEL CABECERO
; Pixel de la esquina, en píxeles
;lon0_pixel=centro_lon_pixel-radio
;lat0_pixel=centro_lat_pixel-radio

; Pixel de la esquina, en coordenadas
;lon0=centro_lon-radio_m
;lat0=centro_lat+radio_m

;print, '*****'
;print, ' ** extensión de la zona 0 en píxeles (x2): ', radio
;print, ' ** extensión de la zona 0 en metros (x2): ', radio_m
;
;print, ' ** pixel central de la zona 0 (lon/pixel): ', centro_lon_pixel
;print, ' ** pixel central de la zona 0 (lat/pixel): ', centro_lat_pixel
;
;print, ' ** pixel "esquina" de la zona 0 (lon/coord): ', lon0
;print, ' ** pixel "esquina" de la zona 0 (lat/coord): ', lat0
;
;print, ' ** pixel "esquina" de la zona 0 (lon/pixel): ', lon0_pixel
;print, ' ** pixel "esquina" de la zona 0 (lat/pixel): ', lat0_pixel
;
;print, 'TAREA (3) "CÁLCULO DE LA ZONA DEL RECORTE":;HECHO!'
```

```
;*****  
; TAREA 4 - TAMAÑO DE PÍXEL DE 20m y 60m A 10m  
;*****  
file_banda2B=reverse(CONGRID(file_banda2B, col10, row10, /INTERP),2)  
file_banda3G=reverse(CONGRID(file_banda3G, col10, row10, /INTERP),2)  
file_banda4R=reverse(CONGRID(file_banda4R, col10, row10, /INTERP),2)  
file_banda5RE1=reverse(CONGRID(file_banda5RE1, col10, row10, /INTERP),2)  
file_banda6RE2=reverse(CONGRID(file_banda6RE2, col10, row10, /INTERP),2)  
file_banda7RE3=reverse(CONGRID(file_banda7RE3, col10, row10, /INTERP),2)  
file_banda8NIR=reverse(CONGRID(file_banda8NIR, col10, row10, /INTERP),2)  
file_banda8ANIR=reverse(CONGRID(file_banda8ANIR, col10, row10, /INTERP),2)  
file_banda11SWIR1=reverse(CONGRID(file_banda11SWIR1, col10, row10, /INTERP),2)  
file_banda12SWIR2=reverse(CONGRID(file_banda12SWIR2, col10, row10, /INTERP),2)  
  
D=SIZE(file_banda11SWIR1)  
col20_10=D(1)  
row20_10=D(2)  
  
print, ' ** Banda 11 (10m)= ',col20_10  
  
print, 'TAREA (4) "CONVERSIÓN A PÍXELES DE 10m":;HECHO!'  
  
;*****  
; TAREA 5 - CREACIÓN DE LA BANDA DEL ÁNGULO SOLAR  
;*****  
  
Z = MAKE_ARRAY(col10, row10, /FLOAT, VALUE = zenith)  
  
print, 'TAREA (5) "BANDA DEL ÁNGULO SOLAR":;HECHO!'  
  
;*****  
; TAREA 6 - CREACIÓN DE LA BANDA NDVI  
;*****  
; CÁLCULO DEL NDVI  
R=file_banda4R  
NIR=file_banda8NIR  
  
NDVI=(1.*NIR-R)/float(1.*NIR+R)  
  
condNDVI=where(NDVI gt 1, contNDVI)  
if contNDVI gt 0 then NDVI(condNDVI)=0  
  
condNDVI=where(NDVI le 0, contNDVI)  
if contNDVI gt 0 then NDVI(condNDVI)=0  
  
print, 'TAREA (6) "CÁLCULO DEL NDVI": ;HECHO!'  
  
;*****  
; TAREA 7 - DEFINICIÓN DE LAS MÁSCARAS  
;*****  
; *** (7.1) ** CREACIÓN DE LAS BANDAS DE CALIDAD  
; *** (7.1.1) ** CLASIFICACIÓN DE LA ESCENA  
bandaSCL=imagen+'_SCL_20m.jp2'  
file_bandaSCL=read_jpeg2000(bandaSCL)  
BQ_escena=reverse(CONGRID(file_bandaSCL, col10, row10, /INTERP),2)  
  
; *** (7.1.2) ** NUBOSIDAD DE LA ESCENA  
bandaCLD=imagen+'_CLD_20m.jp2'  
file_bandaCLD=read_jpeg2000(bandaCLD)  
BQ_nubes=reverse(CONGRID(file_bandaCLD, col10, row10, /INTERP),2)  
  
; *** CONDICIONANTES PARA LAS MÁSCARAS ***  
if clasificada eq 1 then begin  
  
; *** (7.1) ** MÁSCARA DE VALORES ERRÓNEOS DE NDVI  
condNDVI=where(NDVI gt 1, contNDVI)  
if contNDVI gt 0 then NDVI(condNDVI)=-1
```

```
; *** (7.2) ** MÁSCARA SEGÚN LA CLASIFICACIÓN DE LA IMAGEN
; Banda "scene classification" de S2A-L2A
; 0: sin datos
; 1: saturado o defectuoso
; 2: oscuro, sombras
; 3: sombras de nubes
; 4: vegetación
; 5: suelo desnudo, desierto
; 6: agua (toda)
; 7: nubes, probabilidad baja
; 8: nubes, probabilidad media
; 9: nubes, probabilidad alta
; 10: cirros
; 11: nieve o hielo

; PARÁMETROS DE LA ESCENA
ESCENAmín=4
ESCENAmáx=5

; CONDICIÓN DE LA ESCENA PARA LA MÁSCARA
condESCENA1=where(BQ_escena lt ESCENAmín, contESCENA1)
if contESCENA1 gt 0 then NDVI(condESCENA1)=-1

condESCENA2=where(BQ_escena gt ESCENAmáx, contESCENA2)
if contESCENA2 gt 0 then NDVI(condESCENA2)=-1

; *** (7.3) ** MÁSCARA DE NUBES
; Imagen de 0 a 100 - umbral en el 10%
condNUBES=where(BQ_nubes ge 10, contNUBES)
if contNUBES gt 0 then NDVI(condNUBES)=-1

; Opción para la máscara de nubes
; condg_NUBES=where(BQ_nubes(*,*,1) ge 5, contG_NUBES)
; if contG_NUBES gt 0 then NDVI_X=-1

print, 'TAREA (7) "DEFINICIÓN DE LAS MÁSCARAS": ;HECHO!'
endif

if clasificada eq 0 then begin
print, 'TAREA (7) "SIN MÁSCARAS": ;HECHO!'
endif
;*****
; TAREA 8 - SALIDA / ESCRITURA DE LA IMAGEN L2A
;*****
TODAS LAS BANDAS

matL2A=fltarr(col10,row10,nbands)
matL2A(*,*,0)=file_banda2B
matL2A(*,*,1)=file_banda3G
matL2A(*,*,2)=file_banda4R
matL2A(*,*,3)=file_banda5RE1
matL2A(*,*,4)=file_banda6RE2
matL2A(*,*,5)=file_banda7RE3
matL2A(*,*,6)=file_banda8NIR
matL2A(*,*,7)=file_banda8ANIR
matL2A(*,*,8)=file_banda11SWIR1
matL2A(*,*,9)=file_banda12SWIR2
matL2A(*,*,10)=Z
matL2A(*,*,11)=NDVI
matL2A(*,*,12)=BQ_escena

GEO=strcompress(string(UTM),/remove_all)
file_out1=pathout+titulo+'_'+GEO+'_TXK_extraccion'+'_ENVI'

openw,lun,file_out1,/get_lun
writeu,lun,matL2A
```

```
free_lun, lun
```

```
hdr=file_out1+'.hdr'  
descriptor='L2A - 10m'  
nombre_bandas1=['banda2B', 'banda3G', 'banda4R', 'banda5RE1', 'banda6RE2', 'banda7R  
E3', 'banda8NIR', 'banda8ANIR', 'banda11SWIR1', 'banda12SWIR2', 'zenith', 'NDVI', 'BQ  
_escena'];, 'BQ_nubes']
```

```
CABECERO_S2, hdr, descriptor, sensor, order, type, interleave, col10, row10,  
nbands, p, lon, lat, nombre_bandas1
```

```
print, 'TAREA (8) "ESCRITURA DE LA IMAGEN L2A": ;HECHO!'
```

```
;  
; *****  
; TAREA 9 - RECORTE DE LA IMAGEN CON CENTRO CONOCIDO  
; *****  
;; ACTIVAR SI SE REALIZA UN RECORTE DIRECTAMENTE / SE PUEDE UTILIZAR  
ALTERNATIVAMENTE EL MÓDULO DE PROCESADO  
;file_banda1DB_X=file_banda1DB(centro_lon_pixel-  
radio:centro_lon_pixel+radio,centro_lat_pixel-radio:centro_lat_pixel+radio)  
;file_banda2B_X=file_banda2B(centro_lon_pixel-  
radio:centro_lon_pixel+radio,centro_lat_pixel-radio:centro_lat_pixel+radio)  
;file_banda3G_X=file_banda3G(centro_lon_pixel-  
radio:centro_lon_pixel+radio,centro_lat_pixel-radio:centro_lat_pixel+radio)  
;file_banda4R_X=file_banda4R(centro_lon_pixel-  
radio:centro_lon_pixel+radio,centro_lat_pixel-radio:centro_lat_pixel+radio)  
;file_banda5RE1_X=file_banda5RE1(centro_lon_pixel-  
radio:centro_lon_pixel+radio,centro_lat_pixel-radio:centro_lat_pixel+radio)  
;file_banda6RE2_X=file_banda6RE2(centro_lon_pixel-  
radio:centro_lon_pixel+radio,centro_lat_pixel-radio:centro_lat_pixel+radio)  
;file_banda7RE3_X=file_banda7RE3(centro_lon_pixel-  
radio:centro_lon_pixel+radio,centro_lat_pixel-radio:centro_lat_pixel+radio)  
;file_banda8NIR_X=file_banda8NIR(centro_lon_pixel-  
radio:centro_lon_pixel+radio,centro_lat_pixel-radio:centro_lat_pixel+radio)  
;file_banda8ANIR_X=file_banda8ANIR(centro_lon_pixel-  
radio:centro_lon_pixel+radio,centro_lat_pixel-radio:centro_lat_pixel+radio)  
;;file_banda9_X=file_banda9(centro_lon_pixel-  
radio:centro_lon_pixel+radio,centro_lat_pixel-radio:centro_lat_pixel+radio)  
;file_banda11SWIR1_X=file_banda11SWIR1(centro_lon_pixel-  
radio:centro_lon_pixel+radio,centro_lat_pixel-radio:centro_lat_pixel+radio)  
;file_banda12SWIR2_X=file_banda12SWIR2(centro_lon_pixel-  
radio:centro_lon_pixel+radio,centro_lat_pixel-radio:centro_lat_pixel+radio)  
;Z_X=Z(centro_lon_pixel-radio:centro_lon_pixel+radio,centro_lat_pixel-  
radio:centro_lat_pixel+radio)  
;NDVI_X=NDVI(centro_lon_pixel-radio:centro_lon_pixel+radio,centro_lat_pixel-  
radio:centro_lat_pixel+radio)  
;BQ_escena_X=BQ_escena(centro_lon_pixel-  
radio:centro_lon_pixel+radio,centro_lat_pixel-radio:centro_lat_pixel+radio)  
;;BQ_nubes_X=BQ_nubes(centro_lon_pixel-  
radio:centro_lon_pixel+radio,centro_lat_pixel-radio:centro_lat_pixel+radio)  
;  
;mat=fltarr(col0,row0,nbands)  
;;mat(*,*,0)=file_banda1DB_X  
;mat(*,*,0)=file_banda2B_X  
;mat(*,*,1)=file_banda3G_X  
;mat(*,*,2)=file_banda4R_X  
;mat(*,*,3)=file_banda5RE1_X  
;mat(*,*,4)=file_banda6RE2_X  
;mat(*,*,5)=file_banda7RE3_X  
;mat(*,*,6)=file_banda8NIR_X  
;mat(*,*,7)=file_banda8ANIR_X  
;;mat(*,*,9)=file_banda9_X  
;mat(*,*,8)=file_banda11SWIR1_X  
;mat(*,*,9)=file_banda12SWIR2_X  
;mat(*,*,10)=Z_X  
;mat(*,*,11)=NDVI_X  
;mat(*,*,12)=BQ_escena_X
```



```
;;mat(*,*,13)=BQ_nubes_X
;
;file_out11=pathout+titulo+'_'+GEO+'_ENVI_'+X

;openw,lun,file_out11,/get_lun
;writeu,lun,mat
;free_lun,lun
;
;hdr=file_out11+'.hdr'
;descriptor='L2A - 10m - Zona 0'
;nombre_bandas11=['banda2B_zona 0', 'banda3G_zona 0', 'banda4R_zona 0',
'banda5RE1_zona0', 'banda6RE2_zona0', 'banda7RE3_zona0', 'banda8NIR_zona 0',
'banda8ANIR_zona 0', 'banda11SWIR1_zona 0', 'banda12SWIR2_zona 0',
'zenith_zona 0','NDVI_zona 0', 'BQ_escena_zona 0', 'BQ_nubes_zona 0']
;
;CABECERO_S2, hdr, descriptor, sensor, order, type, interleave, col0, row0,
nbands, p, lon0, lat0, nombre_bandas11
;
;print,'TAREA (9) " RECORTE Y ESCRITURA DE LA IMAGEN L2A - ZONA 0": ¡HECHO!'"

print,' * Tiempo de corrección:', systime(1)-T,' segundos'

print,'FIN DE LA CORRECCIÓN, ¡ENHORABUENA!'

END
```

```
PRO CABECERO_S2, hdr, descriptor, sensor, order, type, interleave, col, row,  
nbands, p, X, Y, nombre
```

```
openw, 1, hdr  
  printf, 1, 'ENVI'  
  printf, 1, +descriptor, '['+systime()+']'  
  printf, 1, '  sensor = ',+sensor  
  printf, 1, '  file type = ENVI Standard'  
  printf, 1, '  header offset = 0'  
  printf, 1, '  byte order = ',+order  
  printf, 1, '  data type = ',+type  
  printf, 1, '  interleave = ',+interleave  
  printf, 1, '  samples = ',+col  
  printf, 1, '  lines = ',+row  
  printf, 1, '  bands = ',+nbands  
  printf, 1, '  pixel   = ',+p  
  printf, 1, '  ULX = ',+X  
  printf, 1, '  ULY = ',+Y  
  printf, 1, '  wavelength units = unknown'  
  printf, 1, '  map info = {UTM, 1.5, 1.5, '+strtrim(X,1)+'',  
'+strtrim(Y,1)+'', '+strtrim(p,1)+'', '+strtrim(p,1)+'', 30, North, WGS-84,  
units=Meters}'  
  printf, 1, '  band names= {'  
    for i=1, nbands do begin  
      if i ne nbands then begin  
        printf, 1, nombre(i-1)+'', '  
      endif else begin  
        printf, 1, nombre(i-1)+'}'  
      endelse  
    endfor  
close, 1  
END
```

## CÓDIGO EXTRACTOR

```
PRO EXTRACTOR_S2;

; ** Extracción de los valores de las bandas para unas coordenadas UTM

; INFORMACIÓN DE LA IMAGEN (CABECERO)
; LECTURA DE LOS DATOS DE CAMPO
; EXTRACCIÓN DE LOS VALORES DE LA IMAGEN PARA LOS UTM DESEADOS
; SALIDA DE LOS ARCHIVOS Y DE LA IMAGEN NDVI

;*****
; DATOS DE LA CAMPAÑA
;*****
fecha='20170615'
num=24 ; número de ESU's

;*****
; *** RUTAS DE ENTRADA
path='C:\Users\eolab\Desktop\ENGUERA\'
; *** RUTAS DE SALIDA
; Archivos .txt con los valores extraídos
pathout=path

;*****
; *** ARCHIVOS DE ENTRADA ***
; Fichero de datos de campo
file_ESU=path+'2. COORDENADAS\ENGUERA.txt'

; Imagen
file_ima=path+fecha+'\'+'TC30'
cabecero=path+fecha+'\'+'TC30.hdr'

; *** ARCHIVOS DE SALIDA ***
file_out=path+'5. EXTRACTOR\'+'S2_extract_Enguera_'+fecha+'.txt'

;*****
; INFORMACIÓN DE LA IMAGEN (CABECERO)
;*****
; Lectura del cabecero
openr,lun,cabecero,/get_lun
DATO = ''
for i=0,30 do BEGIN
  readf,lun,DATO
  variables = strsplit(DATO, ' = ' ,/EXTRACT)
  if variables (0) eq 'samples' then begin
    col =fix(variables (1))
  endif
  if variables (0) eq 'lines' then begin
    row =fix(variables (1))
  endif
  if variables (0) eq 'pixel' then begin
    p =fix(variables (1))
  endif
  if variables (0) eq 'bands' then begin
    bands =fix(variables (1))
  endif
  if variables (0) eq 'ULX' then begin
    lon0 =long(float(variables (1)))
  endif
  if variables (0) eq 'ULY' then begin
    lat0 =long(float(variables (1)))
  endif
endif
endfor
```

```
;*****  
print, ' *Columnas =', col  
print, ' *Filas =', row  
print, ' *ULX, lon =', lon0  
print, ' *ULY, lat =', lat0  
  
;*****  
; LECTURA DE LOS DATOS DE CAMPO  
;*****  
openr, lun, file_ESU, /get_lun  
ch= ''  
readf, lun, ch  
print, ' ** Encabezado del fichero de texto: ', ch  
  
lat=dblarr(num)  
lon=dblarr(num)  
a=0.  
b=0.  
  
for n=0,num-1 do begin  
readf, lun, a, b  
lat(n)=a  
lon(n)=b  
endfor  
  
free_lun, lun  
  
;*****  
; EXTRACCIÓN DE LOS VALORES DE LA IMAGEN PARA LOS UTM DESEADOS  
;*****  
coldat=fix(abs((lon)-(lon0-5))/p)  
rowdat=fix(abs((lat0+5)-lat)/p)  
  
print, ' ** Píxeles del muestreo (col/row): '  
print, coldat, rowdat  
  
mat=fltarr(col, row, bands)  
B1=fltarr(num)  
B2=fltarr(num)  
B3=fltarr(num)  
B4=fltarr(num)  
B5=fltarr(num)  
B6=fltarr(num)  
B7=fltarr(num)  
B8=fltarr(num)  
B9=fltarr(num)  
B10=fltarr(num)  
B11=fltarr(num)  
B12=fltarr(num)  
B13=fltarr(num)  
B14=fltarr(num)  
  
print, ' ** Ruta de la imagen: '  
print, file_ima  
openr, lun, file_ima, /get_lun  
readu, lun, mat  
free_lun, lun  
  
print, ' ** Datos de la imagen: dim / col / row / bands / type / píxeles  
totales'  
print, size(mat)  
  
print, ' ** ESU leídas: '  
for n=0,num-1 do begin  
print, n  
B1(n)=mat(coldat(n), rowdat(n), 0)  
B2(n)=mat(coldat(n), rowdat(n), 1)
```

```
B3(n)=mat(coldat(n),rowdat(n),2)
B4(n)=mat(coldat(n),rowdat(n),3)
B5(n)=mat(coldat(n),rowdat(n),4)
B6(n)=mat(coldat(n),rowdat(n),5)
B7(n)=mat(coldat(n),rowdat(n),6)
B8(n)=mat(coldat(n),rowdat(n),7)
B9(n)=mat(coldat(n),rowdat(n),8)
B10(n)=mat(coldat(n),rowdat(n),9)
B11(n)=mat(coldat(n),rowdat(n),10)
B12(n)=mat(coldat(n),rowdat(n),11)
B13(n)=mat(coldat(n),rowdat(n),12)
B14(n)=mat(coldat(n),rowdat(n),13)
endfor

print, '*****'
print, 'Verificación de los valores calculados'
print, '** Longitud: ',lon
print, '** Latitud: ',lat
print, '** Columnas: ',coldat+1 ;suma de la unidad para verificar con ENVI
print, '** Filas: ',rowdat+1 ;suma de la unidad para verificar con ENVI

print, '*****'

;*****
; SALIDA DE LOS ARCHIVOS
;*****
head1 = 'lat'
head2 = 'lon'
head3 = 'col'
head4 = 'row'
head5 = 'B2'
head6 = 'B3'
head7 = 'B4'
head8 = 'B5'
head9 = 'B6'
head10 = 'B7'
head11 = 'B8'
head12 = 'B8A'
head13 = 'B11'
head14 = 'B12'
head15 = 'ANG'
head16 = 'NDVI'
head17 = 'SC'
head18 = 'CL'

openw, lun, file_out, /get_lun

printf, lun, head1, head2, head3, head4, head5, head6, head7, head8, head9, head10, head11,
head12, head13, head14, head15, head16, head17, head18, FORMAT = '(18(A, " "))'

for n=0, num-1 do begin

printf, lun, lat(n), lon(n), coldat(n), rowdat(n), B1(n), B2(n), B3(n), B4(n), B5(n), B6(
n), B7(n), B8(n), B9(n), B10(n), B11(n), B12(n), B13(n), B14(n), FORMAT = '(18(A, " "))'
endfor
free_lun, lun

print, 'EXTRACCIÓN: ;HECHO!'

END
```



## ANEJO 7. Base de Datos





















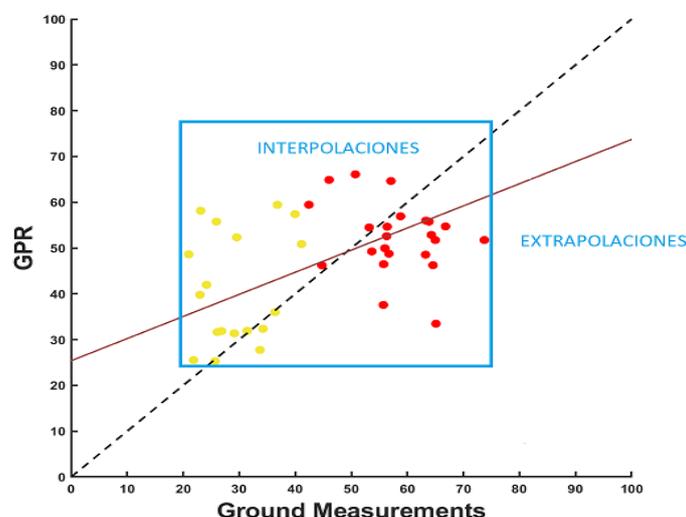


## ANEJO 8. Métodos de aprendizaje automático

El mundo digitalizado en el que vivimos y la mejora de la capacidad computacional de los ordenadores actuales han propiciado el incremento de uso de los métodos de aprendizaje automático. Estos métodos pueden tener múltiples aplicaciones como el reconocimiento de voz, la clasificación de un conjunto de datos o la predicción entre otros.

Nosotros vamos a utilizar estas técnicas para resolver problemas de regresión, en nuestro caso la variable que buscamos predecir "Y" (biomasa) es cuantitativa continua, esto quiere decir que puede tomar cualquier valor.

Éstos modelos nos van a ayudar a producir nuestra variable "Y" a partir de variables "X" si la predicción se encuentra entre los valores de la muestra, entonces la acción de predicción se llamará interpolación en cambio, si la variable predicha esta fuera de rango de los datos de entrada se llama extrapolaciones (Figura 19)



**Figura 19. Predicción variable**

## Tipos de aprendizaje automático

### APRENDIZAJE SUPERVISADO

Los algoritmos de aprendizaje supervisado generan un modelo de predicción a partir de entradas "X" y salidas "Y" conocidas.

El algoritmo aprende comparando el resultado que le da el modelo, con el valor real de la muestra.

### APRENDIZAJE NO SUPERVISADO

Estos Algoritmos funcionan de manera muy parecida a los anteriores, sólo que éstos ajustan el modelo teniendo en cuenta solo las variables de entrada.

De este tipo de algoritmos, el más conocido es el clustering que divide los datos en grupos de características parecidas, utilizado por ejemplo en la compresión de imágenes.

### APRENDIZAJE POR REFUERZO

Es un modelo acción-recompensa, utilizado generalmente para la inteligencia artificial para enseñar a los robots a realizar diversas tareas. El algoritmo crea unas "recompensas" que dependerán de la "acción" que se haya realizado.

### **MODELOS MACHINE LEARNING**

#### MODELO MINIMOS CUADRADOS ORDINARIOS (OLS)

El objetivo de este método es minimizar la suma de los cuadrados de las diferencias entre las respuestas observadas en un conjunto de datos dado y las predichas por el modelo.

Este modelo crea una sola ecuación de regresión simple para representar la relación entre las variables predichas y las observadas.

$$Y = a + b_1 X_1 + b_2 X_2 + \dots + b_n X_n + \text{error}$$

Dónde: Y es la variable dependiente

X son las variables independientes o explicativas

B son los coeficientes de regresión.

Los coeficientes de regresión representan el tipo de relación (positiva o negativa) y el peso (mayor o menor) que tiene la variable a la que acompaña con la variable dependiente.

Es decir si el símbolo del coeficiente ( $b_1$ ) es positivo habrá una relación directa entre esa variable ( $X_1$ ) y la variable dependiente. En cambio si el signo es negativo, se tratará de una relación inversa. Si el valor de  $b_1$  es grande significa que ( $X_1$ ) está altamente relacionada con la variable a predecir.

Este modelo es lineal, por lo que si las variables dependientes e independientes no tiene una relación lineal el modelo no actuará de manera adecuada.

Si hay valores "raros" influirán de manera negativa en la predicción.

Si la relación entre las variables X e Y no son consistentes no servirá el modelo.

### **Valor P**

Casi todos los modelos de regresión realizan una prueba estadística que se llama valor P para los coeficientes de regresión. Esta prueba estadística establece la hipótesis nula: el coeficiente no es muy distinto a cero (lo que quiere decir que no ayuda a la predicción de la variable dependiente) Por lo que si el valor P es pequeño querrá decir que la variable en realidad es importante para la predicción.

### REDES NEURONALES (ANN)

Las redes neuronales son modelos computacionales con diversas aplicaciones como el la predicción de variables, reconocimiento de caracteres, imágenes, voz, prevención de fraude o conducción autónoma entre otros.

Es un sistema muy complejo que surge de la integración de sistemas más simples trabajando conjuntamente, estas partes más simples se denominan neuronas.

Una neurona es la unidad básica de procesamiento que nos vamos a encontrar dentro de una red neuronal, la neurona recibe unos parámetros de entrada y devuelve un valor de salida. Por lo tanto una neurona, se podría decir que no es más que una función. Esta función es una suma ponderada, ya que los parámetros de entrada vienen con un peso o importancia ( $w_1$ ). Una neurona "busca" la regresión lineal

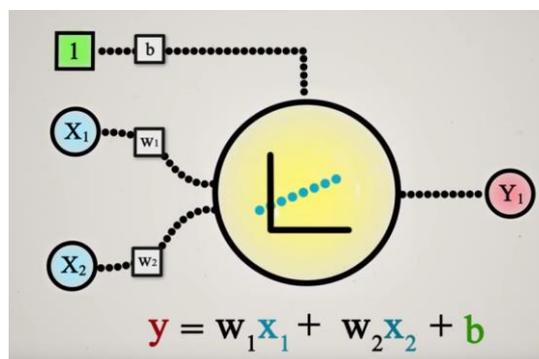


Figura 20. Funcionamiento de una neurona. Fuente: DOTcsv

La neurona calcula la combinación idónea de los pesos para obtener la mejor respuesta Y. La neurona está dotada además de un sesgo b (o bias) que nos permite "mover" la relación lineal, y una función de activación que deforma el resultado de salida para que el resultado sea no lineal y así evitar que la red neuronal colapse (pueden ser sigmoides, tangencial hiperbólica...). Para poder obtener modelos más complejos o con más variables será necesaria la introducción de más neuronas

Las redes neuronales aprenden de los datos gracias a la retro propagación de errores (backpropagation), Una vez la red neuronal ha calculado un resultado, hay que ver cuánto de culpa tiene cada neurona en ese resultado, por lo tanto con un único paso se van asignando la parte de error correspondiente a cada neurona, y así vamos moviéndonos hacia atrás por cada capa de la red neuronal. Por lo tanto con una única pasada hacia atrás el algoritmo ya ha aprendido de sus errores.

El entrenamiento se realiza mediante el algoritmo descenso del gradiente, para ello es necesario conocer el vector gradiente de cada parámetro de cada neurona de la red, y esto se consigue gracias a las derivadas parciales, de dichos parámetros con respecto al coste (es decir el error en el resultado de la red neuronal)

En primer lugar las redes neuronales aplican un peso aleatorio a los parámetros neuronales por lo que el primer resultado de la red (predicho) comparado con lo observado diverja bastante.

Habría que ir calculando las derivadas de los parámetros que forman parte de una función de suma ponderada, dentro de una función de activación y a su vez dentro de la función de coste o error en el resultado. Es decir para hacer las derivadas habría que hacer uso de la regla de la cadena.

$$\frac{\partial C}{\partial b^L} = \delta^L * \frac{\partial z^L}{\partial b^L}$$

$$\frac{\partial C}{\partial w^L} = \delta^L * \frac{\partial z^L}{\partial w^L}$$

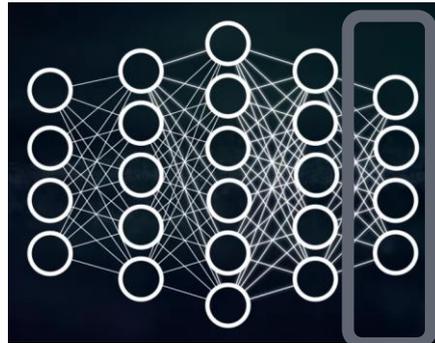


Figura 21. Red neuronal. DOTcsv

Por lo tanto para la primera capa deberíamos calcular el error de cada neurona  $\delta^L$  y las derivadas de la función suma ponderada respecto al bias. Y lo mismo para los parámetros.

En la siguiente capa habría que calcular:

1. COMPUTO DEL ERROR DE LA ULTIMA CAPA

$$\delta^L = \frac{\partial C}{\partial a^L} \cdot \frac{\partial a^L}{\partial z^L}$$

2. RETROPROPAGAMOS EL ERROR A LA CAPA ANTERIOR

$$\delta^{l-1} = W^l \delta^l \cdot \frac{\partial a^{l-1}}{\partial z^{l-1}}$$

3. CALCULAMOS LAS DERIVADAS DE LA CAPA USANDO EL ERROR

$$\frac{\partial C}{\partial b^{l-1}} = \delta^{l-1} \quad \frac{\partial C}{\partial w^{l-1}} = \delta^{l-1} a^{l-2}$$

Figura 22. Formulas capas sucesivas

Así hasta llegar al principio, por lo tanto el algoritmo puede cambiar los pesos iniciales, para conseguir el mejor resultado

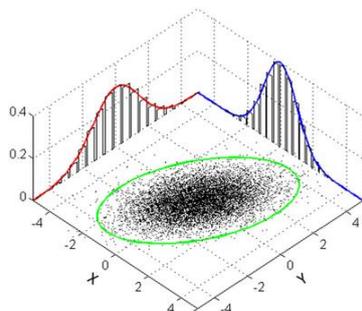
**PROCESOS GAUSSIANOS (GPR)**

Los procesos gaussianos son otro modelo de regresión que se utiliza cuando aparentemente no podemos ver la relación entre los datos de partida.

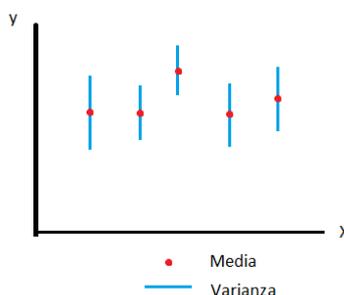
Cuando la variable a predecir se encuentra entre los valores de partida, realizaremos una interpolación, mientras que si la magnitud de la variable a predecir se encuentra fuera del rango de los datos de partida, lo que se realizara será una extrapolación (Figura 19)

Se supone en este método que cualquier colección finita de datos sigue una distribución gaussiana multivariante, es decir que las variables independientes siguen distribuciones Gaussianas, por lo que la combinación entre ellas, también será una distribución Gaussiana, en este caso multivariante.

En la figura 23 podemos ver el resultado de combinar 2 distribuciones Gaussianas mientras que en la figura 24 encontramos 5 distribuciones gaussianas donde el punto rojo indica la media, y las líneas azules las varianzas. En esta representación es más complicado ver la correlación entre variables.



**Figura 23. Distribución Gaussiana 2 variables. Fuente: Galipedia**



**Figura 24. Distribución Gaussiana multivariable**

El proceso Gaussiano consiste en encontrar una función de media y una función de covarianza (o kernel) que se ajuste a todas las distribuciones gaussianas de las variables independientes (Figura 25)

$$\hat{y} = f(x) = \sum_{i=1}^N \alpha_i k(x_i, x) + \alpha_0 \quad k(x_i, x_j) = \sigma_f^2 \exp \left( - \sqrt{\sum_{m=1}^M \frac{(x_{im} - x_{jm})^2}{\sigma_m^2}} \right) \leftarrow \begin{array}{c} \text{ARD} \\ \text{Exponential} \\ \text{Kernel} \end{array}$$

**Figura 25. Formulas procesos Gaussianos**

Para ajustar el proceso: se conoce el conjunto de datos de entrada (variables independientes) y el conjunto de datos de salida (dependiente) que también sigue una distribución gaussiana

Se elige una función Kernel que nos especifica la forma de la función de covarianza de los datos, en nuestro caso hemos elegido una función exponencial separada por variables independientes.

Para el entrenamiento, los procesos gaussianos buscan maximizar el logaritmo de la función de probabilidad de los datos para que la salida sea Gaussiana (máxima verosimilitud). Por lo que una vez estimados los parámetros que maximizan esta función, se recalcula la salida.

A nivel de computacional es fácil de configurar, y rápidamente llega a la solución óptima para la función Kernel establecida, unas de las características de las funciones Kernel es que poseen un valor de determinación automática de relevancia, por lo que se puede saber que variables influyen más en la predicción de la variable dependiente.

### MÁQUINAS DE SOPORTE VECTORIAL (SVM)

Las máquinas de vectores soporte (SVM) también se conocen como SVR cuando se utilizan para resolver problemas de regresión. Son un conjunto de algoritmos de aprendizaje supervisado.

Cuando se tiene un conjunto de datos donde se puede asumir que los valores de la variable dependiente se puede ajustar mediante una función lineal (o no lineal), la máquina de soporte vectorial tiene la función de encontrar los parámetros  $w$  que definen dicha función.

Si queremos permitir el ruido, se utiliza las funciones de pérdida, el uso de dicha función permite que haya dispersión en la solución.

En un principio las SVMs fueron pensadas para resolver problemas de clasificación binaria, actualmente se utilizan para resolver otros tipos de problemas (regresión, agrupamiento, multclasificación).

En el caso de que los datos no puedan ajustarse por una función lineal, se utilizan las funciones kernel.

El uso de una función kernel permite que los datos no separables linealmente lo sean al transformarlos a un espacio con más dimensiones (Figura 26)

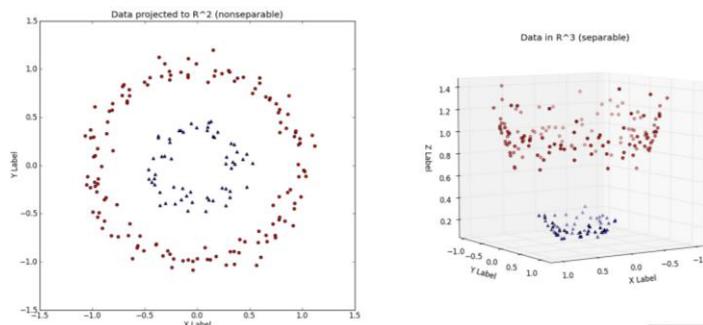


Figura 26. Transformación a partir de kernel. [http://www.eric-kim.net/eric-kim-net/posts/1/imgs/data\\_2d\\_to\\_3d.png](http://www.eric-kim.net/eric-kim-net/posts/1/imgs/data_2d_to_3d.png)



## ANEJO 9. Máquinas entrenadas

En una primera prueba se realiza un entrenamiento con todas las bandas de Sentinel2 y todos los estadísticos de la nube de puntos, para todas las parcelas añadiendo suelo (izq.) y las parcelas sin suelo (derecha)

↓↓ TODAS LAS BANDAS Y TODOS LOS ESTADÍSTICOS DE LiDAR JUNTOS ↓↓

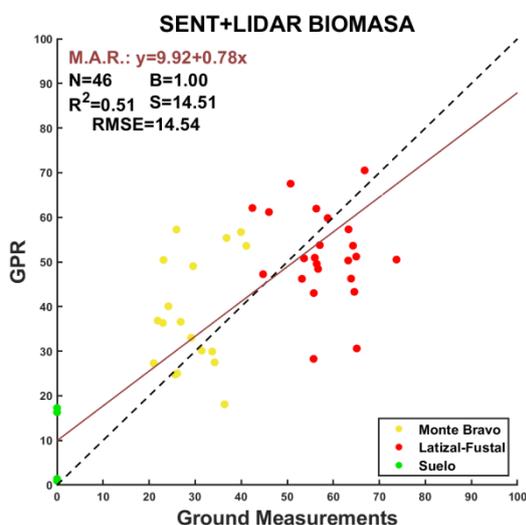


Figura 27. SENTINEL + LiDAR

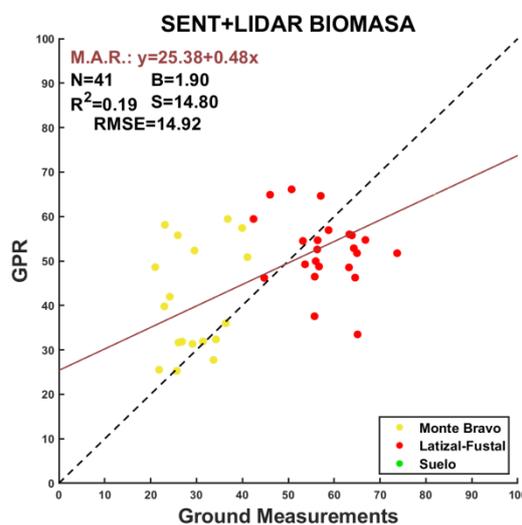


Figura 28. SENTINEL + LiDAR sin suelo

Vemos que los errores medios cuadráticos rondan las 14 toneladas, y el índice de correlación no es muy significativo por lo que se decide probar sólo con las bandas de Sentinel

↓↓ TODAS LAS BANDAS DE SENTINEL ↓↓

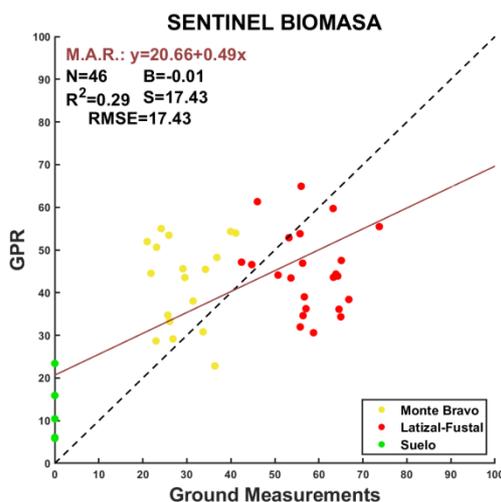
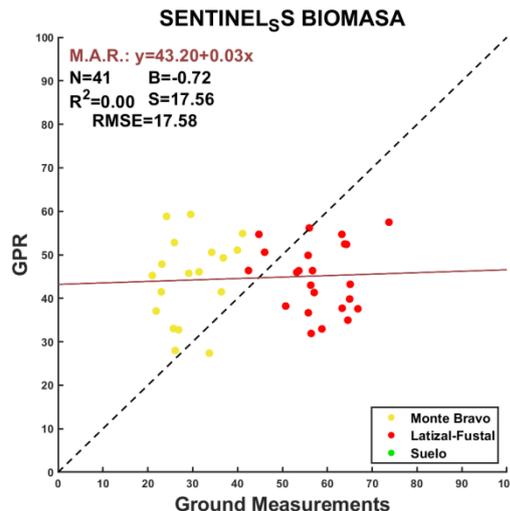


Figura 29. Sentinel con y sin suelo



Vemos que eliminar la información LiDAR empeora un poco los resultados. A

continuación probamos sólo los datos LiDAR

↓↓↓ SOLO LiDAR ↓↓↓

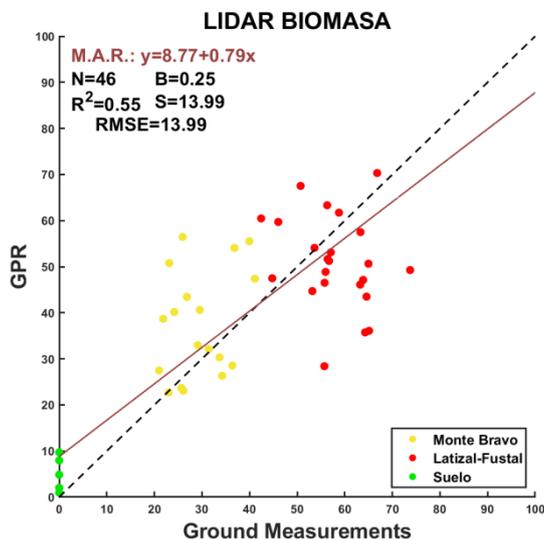


Figura 30. LiDAR

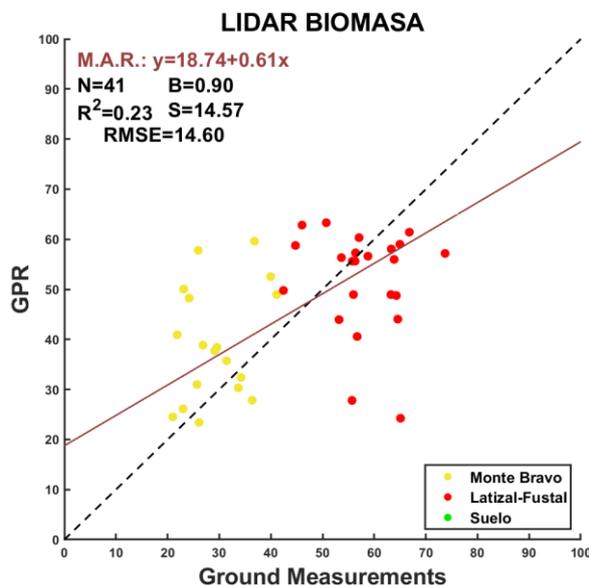


Figura 31. LiDAR sin suelo

A partir de aquí intentamos probar combinaciones de estadísticos LiDAR con reflectividades de Sentinel, la primera prueba que se realiza es la banda NDVI y el percentil 60 de altura de LiDAR además del coeficiente de kurtosis de intensidad

↓↓↓ NDVI KURT P60 ↓↓↓

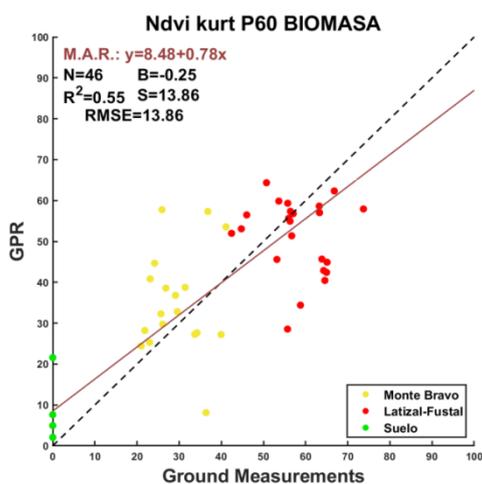
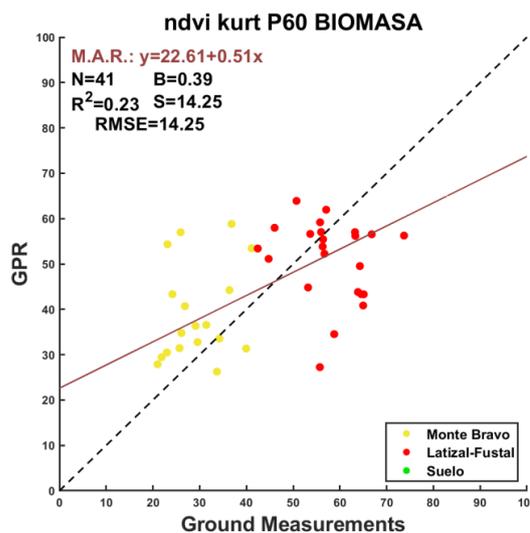


Figura 32. NDVI+KURT+P60



Se prueba varias combinaciones más:

↓↓↓PROBAMOS MIX ↓↓↓

5, 6, 7, 11,12 y 8ª ndvi, y Percentiles 60 a 99 y kurtosis, también densidad de puntos.

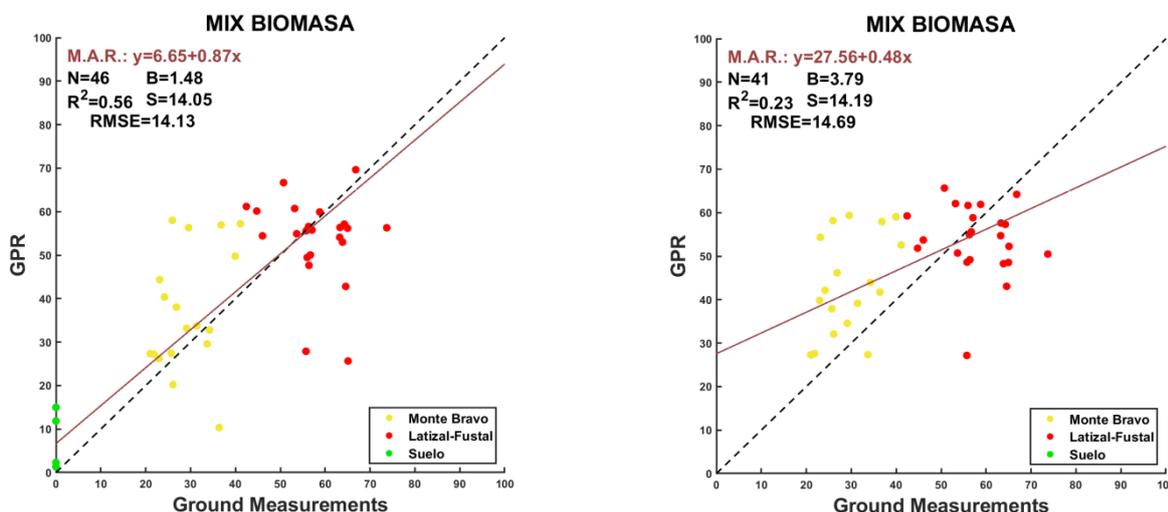


Figura 33. Mix

Vemos que los errores no mejoran significativamente con la introducción de datos LiDAR, por lo que se decide consultar los parámetros Kernel de la combinación de bandas Sentinel, para ver que bandas tienen más peso.

Tabla 16. Parámetros Kernel

banda	Kernel	
NDVI	2.06060021	<div style="display: flex; align-items: center; justify-content: center;"> <div style="margin-right: 10px;">↑</div> <div style="flex-grow: 1; border-left: 1px solid gray; border-right: 1px solid gray; position: relative;"> <div style="position: absolute; top: -10px; left: 50%; transform: translate(-50%, -50%);">↑</div> <div style="position: absolute; bottom: -10px; left: 50%; transform: translate(-50%, -50%);">↓</div> </div> <div style="margin-left: 10px;">↓</div> </div>
B8A	1178.14404	
B8	4528.71577	
p90	527686.506	
ANG	3871923.21	
B4	5865946.16	
B2	18674000	
B3	63155445	
B6	192496093	
B11	205098883	
B7	205890935	
B12	1284983544	
B5	5525450031	

Los parámetros Kernel indican que bandas tienen más importancia a la hora de la predicción, como se puede apreciar en la Tabla 16, las bandas con más peso son: la banda NDVI y la 8A.

A la vez que se puede apreciar que es necesario la introducción de suelo para el

correcto entrenamiento de la máquina.

Además se eliminan varias parcelas de suelo y una parcela, que no era representativa y se decide probar esta combinación.

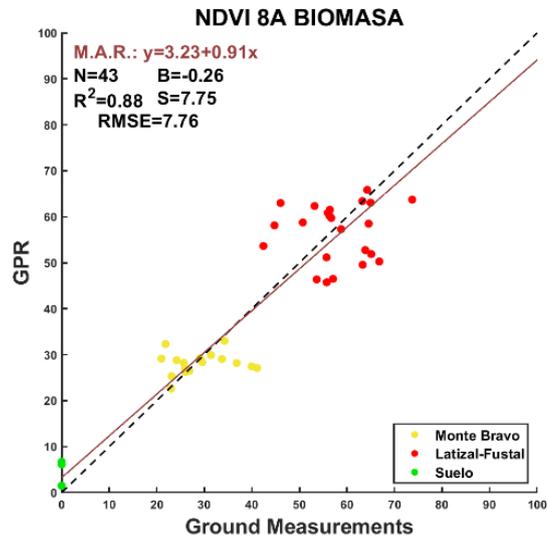


Figura 34. NDVI 8A

Y si a esta misma combinación le añadimos el percentil 90:

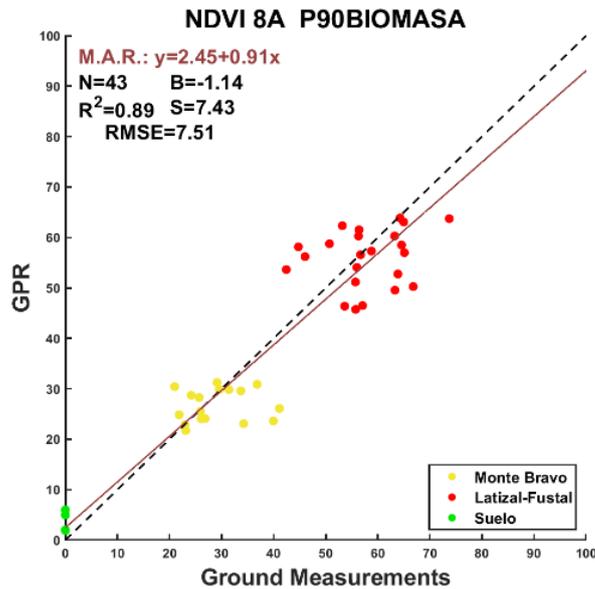


Figura 35. NDVI 8A P90

**Elección banda para el entrenamiento**

Por lo tanto, y como recopilación de las posibles combinaciones tenemos la tabla 17.

Vemos que la mejor combinación es la formada por las bandas NDVI y 8ª

Tabla 17. Resumen combinaciones

BANDAS	BIAS	S	R <sup>2</sup>	RMSE
SENTINEL+LIDAR	1	14.51	0.51	14.54
SENTINEL	-0.01	17.43	0.29	17.43
LIDAR	0.25	13.99	0.55	13.99
NDVI+KURT+P60	-0.25	13.86	0.55	13.86
MIX	1.48	14.05	0.56	14.13
NDVI+8A	-0.26	7.75	0.88	7.76
NDVI+8A+P90	-1.14	7.43	0.89	7.51

La introducción de LiDAR mejora los resultados pero el procesamiento que requiere no es viable para la producción de un mapa de biomasa a escala comunidad autónoma, teniendo en cuenta que cada fichero LiDAR abarca una extensión de 2\*2 km es decir, 400 hectáreas, y solo la Comunidad Valenciana tiene alrededor de 2325500 hectáreas, significaría tener que procesar 580 archivos LiDAR, que, para la poca mejora que produce, no es viable.

Por lo que la combinación elegida es NDVI +8A



## ANEJO 10. Códigos Matlab

## CÓDIGO ENTRENAMIENTO

```
function train_GPR_B2017(combination)
% función que realiza el entrenamiento de las máquinas, siendo combination
% un número que identifica la combinación de bandas.

%% Establecemos la ruta
codes_path=pwd;
path_length=length(codes_path);
general_path=codes_path(1:path_length-5);
dir_basedatos=[general_path,'BBDD_2017nuevaB_SEP'];

productos={'BIOMASA'};
cultivos={'LATIZAL-FUSTAL','MONTE BRAVO'};
subsets={'Subset1','Subset2','Subset3'};

for kk=1:1:length(productos) %productos
    for ii=1:1:length(subsets) %subsets

        var=cell2mat(productos(kk));
        sub=cell2mat(subsets(ii));

        %% Abrimos la base de datos
        switch var
            case 'BIOMASA',[x3,~]= xlsread(dir_basedatos,2);

        end

        %% Leemos las variables necesarias

        switch var
            case 'BIOMASA',Output=x3(:,19);

        end

        id_subset=x3(:,1);

        combination_case=combination;

        switch combination_case
            case 1, Input=[x3(:,26:38),x3(:,46:142)]; name_out='SENTINEL+LIDAR';
            case 2, Input=[x3(:,26:38),x3(:,46:142)]; name_out='SENTIENL +LIDAR
SIN SUELO';
            case 3, Input=[x3(:,26:38)];name_out='SENT ';
            case 4, Input=[x3(:,46:142)];name_out='LIDAR';
            case 5, Input=[x3(:,26:38)];name_out='SENT ';
            case 6, Input=[x3(:,46:142)];name_out='LIDAR';
            case 7,
                Input=[x3(:,37),x3(:,110),x3(:,83)];name_out='ndvi_kurtint_p60';
            case 8,
                Input=[x3(:,37),x3(:,110),x3(:,83)];name_out='ndvi_kurtint_p60 SIN';
            case 9,
                Input=[x3(:,37),x3(:,29:31),x3(:,33:36),x3(:,43),x3(:,110),x3(:,83:90)]; name_out='MIX';
            case 10,
                Input=[x3(:,37),x3(:,29:31),x3(:,33:36),x3(:,43),x3(:,110),x3(:,83:90)]; name_out='MIX
SIN'
            case 18, Input=[x3(:,38),x3(:,33)];name_out='NDVI 8A MONTE BRAVO';
            case 19, Input=[x3(:,38),x3(:,33)];name_out='NDVI 8A
LATIZAL_FUSTAL';
        end

        %% Eliminamos los valores que no sean números
        I = ~isnan(Output);
        Input= Input(I,:);
        Output=Output(I);
        id_subset= id_subset(I);

        In = Input;
        Out=Output;
    end
end
```

```
%% Dividimos los datos en 3 subconjuntos:
% subset 1
if (ii==1)
    cond1=find(id_subset==2 | id_subset==3);
    cond2=find(id_subset==1);
end

% subset 2
if (ii==2)
    cond1=find(id_subset==1 | id_subset==3);
    cond2=find(id_subset==2);
end

% subset 3
if (ii==3)
    cond1=find(id_subset==1 | id_subset==2);
    cond2=find(id_subset==3);
end

Learn.P = In(cond1,:);
Learn.T = Out(cond1);

Valid.P = In(cond2,:);
Valid.T = Out(cond2);

%% Entrenamos el gaussian process
gprMdl = fitrgp(Learn.P,Learn.T,'KernelFunction','ardexponential');
path_redes=[general_path,'RESULTS\REDES\'];
GP.(sub)=gprMdl;
end
end
%end
%% Guardamos
save ([path_redes,'NET_GP_C',int2str(combination)],'GP');

end
```

## CÓDIGO VALIDACIÓN

```
function make_GPR_generic_BIOMASA_separado(combination)
%Especificamos la ruta
codes_path=pwd;
path_length=length(codes_path);
general_path=codes_path(1:path_length-5);
dir_basedatos=[general_path,'BDD_2017nuevaB'];%

productos={'BIOMASA'};
subsets={'Subset1','Subset2','Subset3'};
load([general_path,'RESULTS\REDES\NET_GP_C',int2str(combination)]); % cargamos
la red de la combinacion seleccionada

for kk=1:1:length(productos) %productos
    for ii=1:1:length(subsets) %subsets

        var=cell2mat(productos(kk));
        sub=cell2mat(subsets(ii));

        sprintf('voy por el producto: %s',var)
        sprintf('voy por el subset: %s',sub)

        %% Abrimos la base de datos
        switch var
            case 'BIOMASA',[x3,~]= xlsread(dir_basedatos,2);%SELECCIONO LA
HOJA DE LA BASE DE DATOS

        end

        %% Leemos las variables necesarias
        switch var
            case 'BIOMASA',Output=x3(:,19);
        end

        id_subset=x3(:,1);
        id_estruc=x3(:,21);

        %% Lectura Input(reflectividad)
        combination_case=combination;

        switch combination_case
            case 1, Input=[x3(:,26:38),x3(:,46:142)];
name_out='SENTINEL+LIDAR';
            case 2, Input=[x3(:,26:38),x3(:,46:142)];
name_out='SENTIENL +LIDAR SIN SUELO';
            case 3, Input=[x3(:,26:38)];name_out='SENT ';
            case 4, Input=[x3(:,46:142)];name_out='LIDAR';
            case 5, Input=[x3(:,26:38)];name_out='SENT ';
            case 6, Input=[x3(:,46:142)];name_out='LIDAR';
            case 7,
Input=[x3(:,37),x3(:,110),x3(:,83)];name_out='ndvi_kurtint_p60';
            case 8,
Input=[x3(:,37),x3(:,110),x3(:,83)];name_out='ndvi_kurtint_p60 SIN';
            case 9,
Input=[x3(:,37),x3(:,29:31),x3(:,33:36),x3(:,43),x3(:,110),x3(:,83:90)];name_o
ut='MIX';
            case 10,
Input=[x3(:,37),x3(:,29:31),x3(:,33:36),x3(:,43),x3(:,110),x3(:,83:90)];name_o
ut='MIX SIN SUELO';
            case 18, Input=[x3(:,38),x3(:,33)];name_out='NDVI 8A MONTE
BRAVO';
```

```
case 19, Input=[x3(:,38),x3(:,33)];name_out='NDVI 8A
LATIZAL_FUSTAL';
end

%% Eliminamos los valores que no sean números
I = ~isnan(Output);
Input= Input(I,:);
Output=Output(I);
id_subset= id_subset(I);
id_estruc= id_estruc(I);

In = Input;
Out=Output;

%% Dividimos los datos en 3 subconjuntos:
% subset 1
if (ii==1)
    cond1=find(id_subset==2 | id_subset==3);
    cond2=find(id_subset==1);
end

% subset 2
if (ii==2)
    cond1=find(id_subset==1 | id_subset==3);
    cond2=find(id_subset==2);
end

% subset 3
if (ii==3)
    cond1=find(id_subset==1 | id_subset==2);
    cond2=find(id_subset==3);
end

Learn.P = In(cond1,:);
Learn.T = Out(cond1);

%% Con puntos de suelo
Valid.P = In(cond2,:);
Valid.T = Out(cond2);
id_estruc = id_estruc(cond2);

anterior %% Se carga el modelo de regresión obtenido con el programa
gprMdl=GP.(sub);

%% Se predicen los puntos
[Var_Valid,~,~] = predict(gprMdl,Valid.P);
out_GP=Var_Valid;
out_Measurements=Valid.T;

%% Concatenamos todos los resultados:
if (ii==1)
    out_GP_concat=out_GP;
    out_Measurements_concat=out_Measurements;
    estruc_concat=id_estruc;
    N=length(out_Measurements_concat);
    fprintf('N= %d\n',N);

else

    out_GP_concat=[out_GP_concat;out_GP];
```



```
text(axismin+0.3/4*(axismax-axismin),axismin+0.81*(axismax-  
axismin),['RMSE=',num2str(error,'%0.2f')], 'FontSize',16,'FontWeight','bold');  
text(axismin+0.8/4*(axismax-axismin),axismin+0.91*(axismax-  
axismin),['B=',num2str(berror,'%0.2f')], 'FontSize',16,'FontWeight','bold');  
text(axismin+0.8/4*(axismax-axismin),axismin+0.86*(axismax-  
axismin),['S=',num2str(s,'%0.2f')], 'FontSize',16,'FontWeight','bold');  
  
X=(axismin:0.01:axismax);  
Y=b(1)+b(2)*X;  
plot(X,X,'k--','LineWidth',1.5);  
plot(X,Y,'Color',color_marron,'LineWidth',1.5);  
  
xlabel('Ground Measurements','FontSize',18);  
ylabel('GPR','FontSize',18);  
set(gca,'linewidth',1.5)  
set(gca,'FontWeight','bold')  
titu=['NDVI 8A LATIZAL FUSTAL ',var];  
title(['\fontsize{20}',titu]);  
lgnd=legend({'Monte Bravo','Latizal-  
Fustal','Suelo'}, 'FontSize',12,'Location','southeast');  
set(lgnd,'Color','none'); % para que la leyenda sea transparente  
por si cae algun punto dentro  
%% Guardamos la figura  
print(gcf, '-dpng',  
[general_path,'RESULTS\SCATTERS\ScatterGP_',var,'_',int2str(combination),'.png'  
]);  
  
saveas(gcf,[general_path,'RESULTS\SCATTERS\ScatterGP_',var,'_',int2str(combination),'.fig'],'fig')  
hold off  
close(ff)  
  
end
```

## CÓDIGO GENERACIÓN IMÁGENES DE BIOMASA

```
function CV_MAP(combination)

tic

codes_path=pwd;
path_length=length(codes_path);
general_path=codes_path(1:path_length-5);

productos={'BIOMASA'};
subsets={'Subset1','Subset2','Subset3'};
load([general_path,'RESULTS\REDES2017\NET_GP_C',int2str(combination)])
; % cargamos la red de la combinacion seleccionada

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

row=10980;
col=10980;
bandas=2;
fecha=20170506;
zona=30;

%%ABRIMOS LA IMAGEN

fid=fopen('C:\Users\silvi\Desktop\tutorial_GPR\tutorial_GPR\S2_2017061
5_30_SYJ_NDVI_8A','r');
    In_data=fread(fid,'float');
    fclose(fid);
    data=reshape(In_data,[row,col,bandas]);

    In_data=0;

for kk=1:length(productos) %productos
    for ii=1:length(subsets) %subsets
        var=cell2mat(productos(kk));
        sub=cell2mat(subsets(ii));

        sprintf('voy por el producto: %s',var)
        sprintf('voy por el subset: %s',sub)
        sprintf('estoy pensando')

        %% Lectura Input(reflectividad)
        Input=reshape(data,[row*col,2]); %Poner los datos
en2columnas

        gprMdl=GP.(sub);
        [Var_Valid,~,~] = predict(gprMdl,Input); %por defecto
alpha 0.05

        out_GP=Var_Valid;

        % % % % % % % % % concatenamos todos los resultados:
        out_GP_concat(:,ii)=Var_Valid;

    end %subsets
```



```
out=mean(out_GP_concat,2); %media de los 3 subsets
out=reshape(out,[row,col]);
out_all(:, :,kk)=out;
end %productos

%% Guardar en geotiff
for pp=1:length(productos)
out_all_v2(:, :,pp)=out_all(:, :,pp)';
end

R = maprasterref('RasterSize', [row,col], ... %tamaño
(pixels) del mapa
'YWorldLimits', [4290240 4400040],
'ColumnsStartFrom','north', ... %(lat min y max)[ymin-10 ymax]
'XWorldLimits', [699960 809760]);%(long min y max) [xmin
xmax+10]

filename=[general_path,'\MAP_biomasa_CV_LATIZALFUSTAL_SYJ_out_',num2st
r(fecha),'_',num2str(zona)];

geotiffwrite(filename,out_all_v2,R,'CoordRefSysCode',32630) %%
toc
end %funcion
```



## ANEJO 11. Segmentación SIG

Una vez obtenidas las imágenes de biomasa se procede a la segmentación SIG para la generación de los mapas de Biomasa.

Debido al peso de las imágenes ( alrededor de 1 Gb cada una) se ha decidido hacer un tratamiento por separado, en lugar de por mosaico.

El primer mapa que se generó fue el mapa de Biomasa para las zonas de *Pinus halepensis*, consiste en un mapa raster con valores de Biomasa en las zonas de *Pinus halepensis*, y valor no Data para otras zonas.

Para ello se cargaron todas las imágenes de monte bravo en el software ArcMap y se le realizó un *extract by mask* siendo la máscara, la selección monte-bravo de la capa HALEPENSIS\_SEGMENTACIÓN(figura 36)

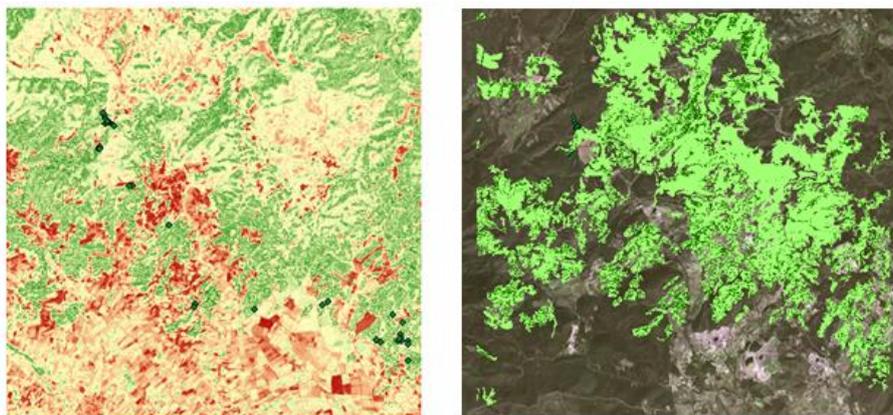


Figura 36. Ejemplo Extract by mask

Se hizo lo propio con las imágenes de latizal-fustal (cambiando la selección de la capa de HALEPENSIS\_SEGMENTACIÓN)

A continuación con la capa *mosaic to new raster* se juntaron todas las imágenes de monte bravo (un total de 7)) y se generó el mapa de biomasa de *Pinus Halepensis* en monte bravo para la Comunidad Valenciana

Se hizo lo mismo con las imágenes de latizal fustal (también 7 imágenes) y se generó el mapa de biomasa de *Pinus Halepensis* en latizal y fustal para la comunidad Valenciana.

Al final se juntaron sendos mapas, para generar el mapa de biomasa de *Pinus Halepensis* para la Comunidad Valenciana, (figura 37)



Figura 37. Resultado mapa Biomasa en zonas de *Pinus halepensis*

También se generó otro mapa de biomasa en la comunidad Valenciana. Para ello se tomaron las imágenes de latizal-fustal completas y se recortaron una a una para que cogieran la extensión de la comunidad Valenciana.(Figura 38)

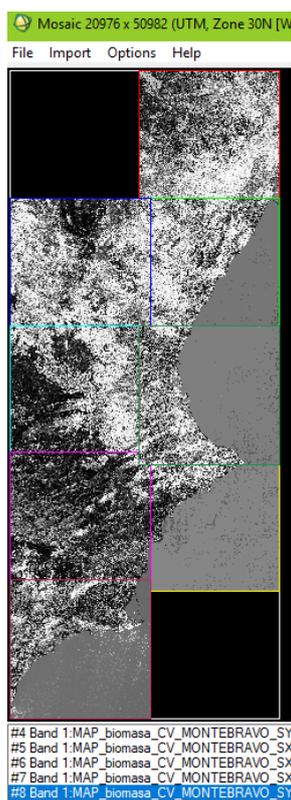


Figura 38. Mosaico de Imágenes Sentinel (izquierda) Resultado de la unión y recorte de las imágenes del mosaico (derecha)

A continuación se superpuso el raster de monte bravo, y se guardó mediante *mosaic to new raster* indicando los parámetros necesarios para que se guardaran los valores de latizal-fustal como base y superpuestos los valores de monte bravo, consiguiendo así el mapa de Biomasa para la Comunidad Valenciana (ver en Cartografía Generada)



**ANEJO 12. Comunicación con la Dirección General de Desarrollo rural  
Innovación y Política Forestal**



*Estimada señora Aparisi:*

*En relación con su consulta sobre el IFN4 de la Comunidad Valenciana, le informamos de que no se ha realizado por el momento, la información más actualizada es la que está utilizando, el IFN3.*

*El IFN4 de la Comunidad Valenciana no está realizado ni previsto próximamente. Antes están programadas las CCAA de Castilla y León (en ejecución), Castilla - La Mancha (inicio de los trabajos en 2019) y Aragón.*

*Respecto a su segunda pregunta, sobre las labores selvícolas, no se dispone en esta unidad de información de detalle.*

*Existen estadísticas de cortas proporcionadas por las comunidades autónomas, que puede consultar en el Anuario de Estadística Forestal, disponible en la web del departamento, en el siguiente enlace:*

[https://www.mapa.gob.es/es/desarrollo-rural/estadisticas/forestal\\_anuarios\\_todos.aspx](https://www.mapa.gob.es/es/desarrollo-rural/estadisticas/forestal_anuarios_todos.aspx)

*La gestión forestal es una competencia autonómica, por lo que le sugerimos que se ponga en contacto con la administración forestal de su comunidad autónoma, por si ellos pueden proporcionarle información de mayor detalle.*

*Saludos cordiales*



## ANEJO 13. Clasificación climática de Köppen-Geiger

El meteorólogo y científico Wladimir Peter Köppen creó la clasificación que lleva su nombre para la identificación de cada tipo de clima con respecto al comportamiento de las precipitaciones y las temperaturas que presentaba cada clima.

Según esta clasificación el clima predominante en la comunidad Valenciana es el Csa

- C de templado
- S de verano seco
- A de Subtropical

Este clima se caracteriza por lluvias estacionales y temperaturas altas o cálidas en verano, también es conocido como clima Mediterráneo de verano cálido.

Por lo tanto en trabajos futuros esta clasificación nos va delimitar las zonas de estudio ya que estudiaremos las estructuras forestales atendiendo a su clasificación climática.

Se ha generado una capa vectorial a partir de una imagen ráster de clasificación climática de Köppen –Geiger realizados por José Ángel Núñez Mora, técnico de AEMET([jnunezm@aemet.es](mailto:jnunezm@aemet.es)) que se adjunta en el presente anejo.



## ANEJO 14. Herramienta cálculo de biomasa

