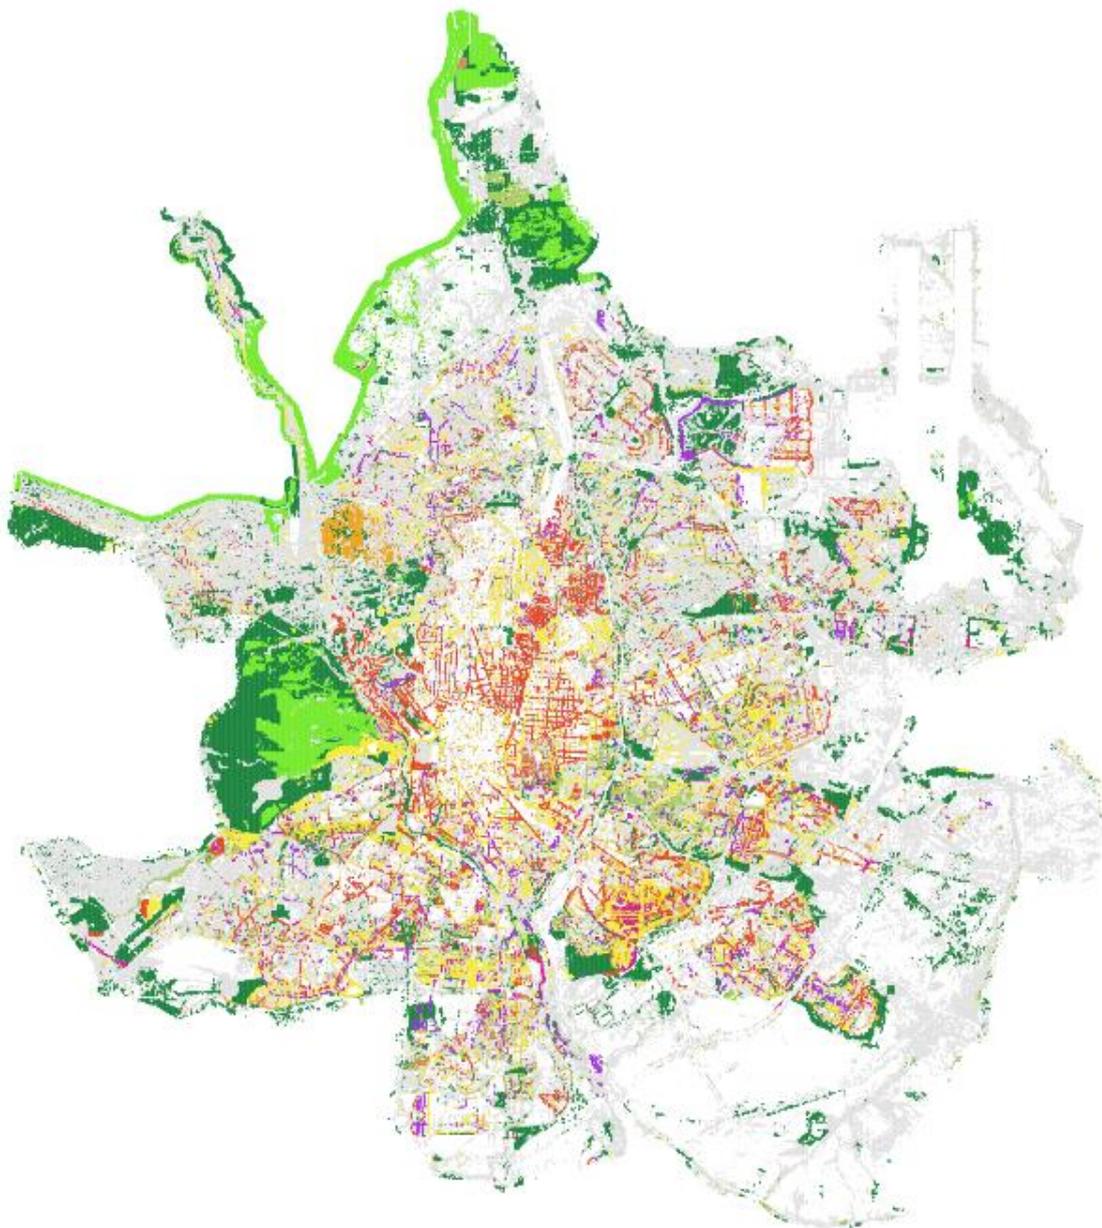


2023

Centro de Observación y
Teledetección Espacial,
S.A.U.

(COTESA – A47461066)



SERVICIO DE CARTOGRAFÍA DE ESPECIES

[Metodología para la detección de especies en el segundo semestre de 2023 sobre el término municipal de Madrid más las pistas del aeropuerto Adolfo Suárez – Madrid Barajas sin el Monte del Pardo.]

Contenido

1.	Introducción.....	2
2.	Objetivo.....	2
3.	Metodología.....	2
3.1.	Cálculo de índices.....	2
3.2.	Selección de áreas de entrenamiento.....	4
3.3.	Clasificación por píxel.....	5
3.4.	Resultados.....	6
3.5.	Entregables.....	8

1. Introducción.

En este informe se muestra la metodología utilizada para la obtención de especies en Madrid para el segundo semestre del año 2023. Para ello se ha utilizado un algoritmo propio de COTESA que permite la automatización de cartografía de coberturas de suelo de alta resolución. Es una herramienta diseñada en software libre, que permite la semi- automatización de la cartografía de ocupación del suelo y con mayor precisión y recurrencia que la cartografía existente actual, estos algoritmos han sido modificados para así poder determinar qué especies pueden ser detectadas.

Mediante la clasificación supervisada basada en píxeles del mosaico obtenido anteriormente, se logra una cartografía de coberturas basadas en la detección de especies, que son 10 clases genéricas y una que engloba a otras especies, teniendo así: Pino, Falso Platanero, Arce, Olmo, Acacia, Falsa Acacia, Almez, Aligustre, Castaño, Encina y otros (resto de especies arbóreas). Se automatiza así el cartografiado de especies arbóreas que serán englobadas en teselas de 20x20 metros donde prevalecerá la especie con mayor superficie.

2. Objetivo.

Obtención de una capa shapefile y raster donde queden reflejadas las especies arbóreas para el segundo semestre de 2023, para el término municipal de Madrid (más pistas del Aeropuerto Adolfo Suárez - Madrid Barjas).

Aunque se utilicen índices espectrales de verano se consideran del segundo semestre ya que las bandas espectrales son las de la imagen de otoño, es decir las bandas de otoño más los índices de la misma fecha a la que se añaden los índices de verano para obtener más información.

3. Metodología.

A continuación, se describe cada una de las fases llevadas a cabo para la obtención de las especies, que radica en varios procesos.

3.1. Cálculo de índices.

El cálculo de índices corresponde a la preparación de las imágenes para poder realizar operaciones de segmentación y clasificación.

El uso de índices espectrales para facilitar la clasificación de la imagen procede de dos índices diferentes, NDVI y RVI. Con estos índices adquirimos información explícita sobre vegetación y agua que favorecerá la clasificación de estas zonas.

- NDVI (Índice de Vegetación de Diferencia Normalizada): es un índice usado para estimar la cantidad, calidad y desarrollo de la vegetación con base a la medición (por medio de sensores remotos instalados comúnmente en una plataforma espacial) de la intensidad de la radiación de ciertas bandas del espectro electromagnético que la vegetación emite o refleja.

$$NDVI = \frac{(NIR - Red)}{(NIR + Red)}$$

- RVI (Índice Relativo de Vigor): es una relación entre la reflectancia registrada en las bandas de infrarrojo cercano (NIR) y rojo. Esta es una forma rápida de distinguir las hojas verdes de otros objetos en la escena y estimar la biomasa relativa presente en la imagen. Además, este valor puede ser muy útil para distinguir la vegetación estresada de las áreas no estresadas.

$$RVI = \frac{NIR}{RED}$$



Imagen 1. NDVI a la izquierda, RVI a la derecha.

La combinación de los resultados de ambos índices se une, como si de dos bandas más se tratase al mosaico original y aportando así una información extra al mismo.

Esta operación se repetirá con la imagen de verano de 2023, con ello conseguiremos tener dos imágenes diferentes con 2 índices cada una, es decir tendremos una sola imagen con 12 bandas (RGB-NIR-NDVI-RVI del primer semestre de 2023 y RGB-NIR-NDVI-RVI de segundo semestre de 2023), esta variabilidad temporal permitirá tener un mayor volumen de datos por especie, favoreciendo así la clasificación de las mismas.

3.2. Selección de áreas de entrenamiento.

Las áreas de entrenamiento se obtienen mediante una capa de especies arbóreas entregada por cliente. Esta capa, de puntos, es la utilizada como entrada para el algoritmo, como se puede observar en la Imagen 2.

Es en este paso en el que, en función del número de muestras, así como de la representatividad de las mismas se decide qué especies pueden ser las más idóneas para que sean detectadas, teniendo en cuenta varios aspectos, como la estacionalidad, la respuesta espectral, etc. Y de las 769.293 muestras, se observa que las que mayor probabilidad tienen de ser detectadas por sus características son las 10 clases previamente dichas.

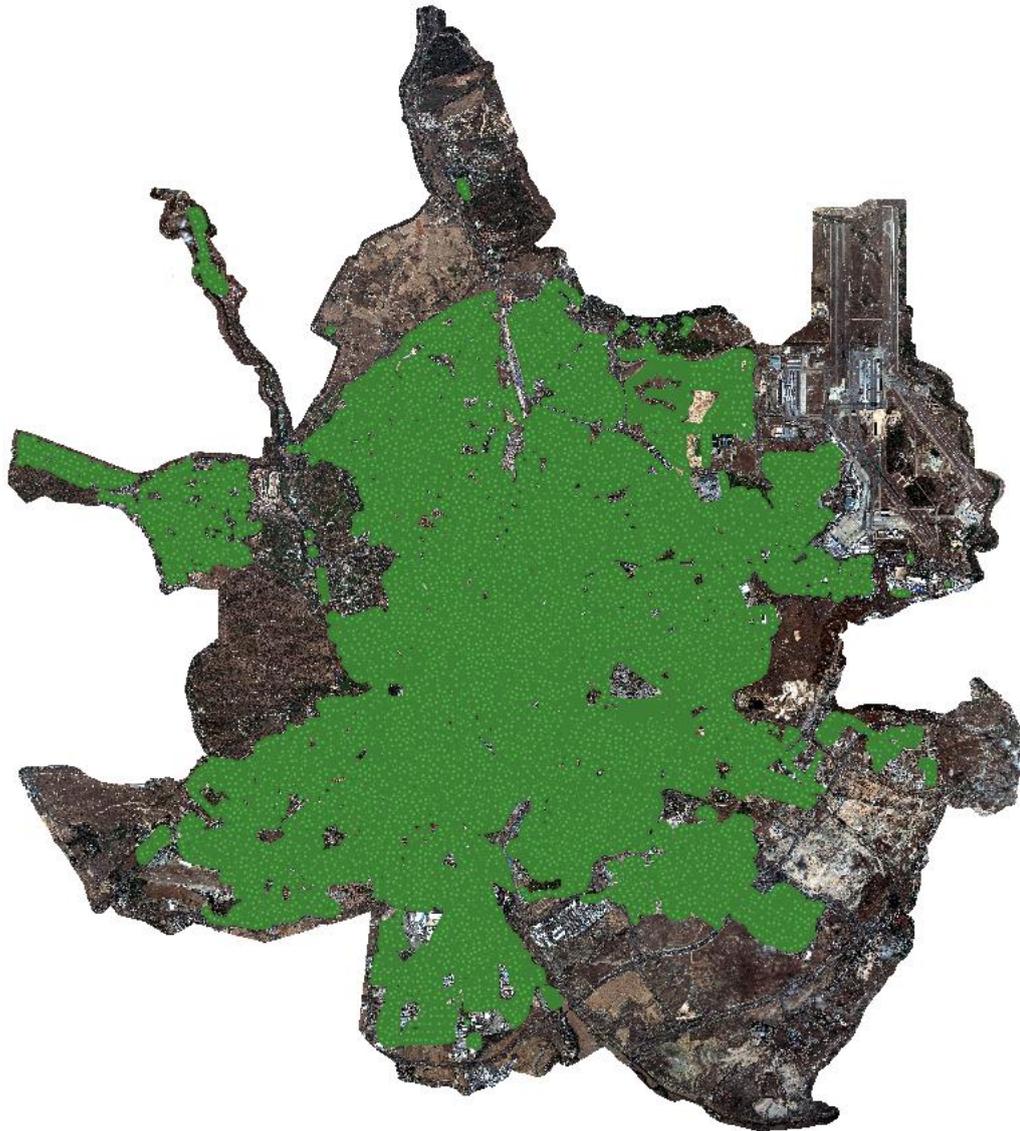


Imagen 2. Puntos utilizados como áreas de entrenamiento para la detección de especies.

3.3. Clasificación por píxel.

La clasificación se realizará con los puntos obtenidos de la capa que fue provisionada, y a diferencia que en la detección de zonas verdes (donde las áreas de entrenamiento eran polígonos en los que se creaban puntos aleatorios y posteriormente se filtraban) no se filtrarán los puntos más que por las especies a detectar, salvo la clase otros donde se engloban todas aquellas especies que no van a poder ser detectadas individualmente. De estos puntos serán extraídas las estadísticas de las diferentes bandas del mosaico (recordad que cuenta con 12 bandas diferentes), siendo estos datos con los que el algoritmo entrenará obteniendo un modelo de clasificación.

Tras esto se utilizarán las siguientes herramientas:

- *ComputeImageStatistics*.
- *TrainVectorClassifier* donde se elegirá el método de entrenamiento de clasificación que es el *Random Forest*.
- *ImageClassifier* que utilizando las estadísticas previas clasificará la imagen.

Tras ello se realizan una serie de procesos para obtener los segmentos, siendo éstos un filtrado de los píxeles para así poder depurar la imagen omitiendo el ruido que pueda haber en la clasificación mediante la herramienta de *Filtrado*, seguido de la utilización de la herramienta de ráster a polígono (*poligonizar*), y finalmente la herramienta *dissolve* de las clases obtenidas, como se puede observar en la imagen 3.

origenFid	_0	_1	_2	_3	_4	_5	_6	_7	_8	_9
7450	673,0000000000	868,0000000000	1371,0000000000	1773,0000000000	1893,0000000000	2336,0000000000	2484,0000000000	2577,0000000000	0,136995673179	-0,290556281980
7453	728,0000000000	955,0000000000	1400,0000000000	1921,0000000000	2081,0000000000	2266,0000000000	2362,0000000000	2278,0000000000	0,062623660474	-0,225974023334
7454	531,0000000000	696,0000000000	1188,0000000000	1578,0000000000	1751,0000000000	1853,0000000000	1914,0000000000	1812,0000000000	0,044474761833	-0,233644859000
7458	477,0000000000	639,0000000000	975,0000000000	1287,0000000000	1407,0000000000	1633,0000000000	1767,0000000000	1837,0000000000	-0,113421551883	-0,2884026408
7514	342,0000000000	555,0000000000	876,0000000000	1878,0000000000	2115,0000000000	2988,0000000000	3348,0000000000	3484,0000000000	0,225700168801	-0,548596162338
7520	81,0000000000	189,0000000000	284,0000000000	322,0000000000	368,0000000000	803,0000000000	1284,0000000000	1318,0000000000	0,549079634723	-0,613074698250
7523	548,0000000000	735,0000000000	1128,0000000000	1473,0000000000	1598,0000000000	1928,0000000000	2141,0000000000	2197,0000000000	0,145838901400	-0,308800703600
7524	477,0000000000	696,0000000000	960,0000000000	1391,0000000000	1501,0000000000	1918,0000000000	2218,0000000000	2415,0000000000	0,193358432578	-0,395405989884
7527	181,0000000000	331,0000000000	558,0000000000	899,0000000000	821,0000000000	1595,0000000000	2374,0000000000	2481,0000000000	0,485142326934	-0,619372427360
7529	294,0000000000	485,0000000000	687,0000000000	1031,0000000000	1174,0000000000	1543,0000000000	1779,0000000000	1863,0000000000	0,204876293879	-0,438995148000
7530	353,0000000000	644,0000000000	1011,0000000000	1683,0000000000	1955,0000000000	2488,0000000000	2778,0000000000	2824,0000000000	0,174859987968	-0,466480773340
7531	351,0000000000	511,0000000000	790,0000000000	1091,0000000000	1177,0000000000	1799,0000000000	2286,0000000000	2526,0000000000	0,320242533483	-0,486345919980
7532	382,0000000000	653,0000000000	938,0000000000	1261,0000000000	1386,0000000000	1975,0000000000	2418,0000000000	2599,0000000000	0,271484881639	-0,441167712210
7533	247,0000000000	442,0000000000	781,0000000000	1038,0000000000	1203,0000000000	2259,0000000000	3281,0000000000	3399,0000000000	0,463423517882	-0,623453736300
7534	215,0000000000	410,0000000000	748,0000000000	1163,0000000000	1351,0000000000	2426,0000000000	3257,0000000000	3565,0000000000	0,413628458876	-0,626466029910
7537	366,0000000000	602,0000000000	1031,0000000000	2056,0000000000	2565,0000000000	3197,0000000000	3487,0000000000	3477,0000000000	0,152346327800	-0,543803368685
7539	375,0000000000	621,0000000000	1077,0000000000	2198,0000000000	2735,0000000000	3438,0000000000	3642,0000000000	3761,0000000000	0,142226884862	-0,543547332280
7542	164,0000000000	256,0000000000	449,0000000000	840,0000000000	977,0000000000	1285,0000000000	1447,0000000000	1397,0000000000	0,193884386291	-0,524871300320
7546	201,0000000000	376,0000000000	664,0000000000	1381,0000000000	1664,0000000000	2184,0000000000	2396,0000000000	2382,0000000000	0,159595968339	-0,381351368420
7588	408,0000000000	679,0000000000	1121,0000000000	1951,0000000000	2324,0000000000	3272,0000000000	3881,0000000000	3932,0000000000	0,258625673412	-0,551776279170
7589	180,0000000000	281,0000000000	487,0000000000	852,0000000000	1145,0000000000	1477,0000000000	1543,0000000000	1552,0000000000	0,148065417809	-0,535323381420
7814	1157,0000000000	1438,0000000000	1807,0000000000	871,0000000000	764,0000000000	1147,0000000000	1683,0000000000	1846,0000000000	0,378809180450	-0,128247173960
7815	1496,0000000000	1778,0000000000	1482,0000000000	962,0000000000	891,0000000000	765,0000000000	1114,0000000000	1188,0000000000	0,247127503044	0,130593161424
7881	588,0000000000	864,0000000000	828,0000000000	903,0000000000	966,0000000000	1058,0000000000	1078,0000000000	1124,0000000000	0,054784520139	-0,131164744480
8067	43,0000000000	81,0000000000	150,0000000000	199,0000000000	177,0000000000	252,0000000000	568,0000000000	681,0000000000	0,524832189983	-0,382172691982
8068	12,0000000000	48,0000000000	116,0000000000	115,0000000000	107,0000000000	461,0000000000	964,0000000000	1031,0000000000	0,803849697113	-0,788090931410
8069	14,0000000000	72,0000000000	146,0000000000	143,0000000000	138,0000000000	704,0000000000	1478,0000000000	1566,0000000000	0,328996306697	-0,619975318520
8070	12,0000000000	59,0000000000	128,0000000000	123,0000000000	119,0000000000	545,0000000000	1161,0000000000	1233,0000000000	0,814062476158	-0,861396429530

Imagen 3. Datos obtenidos de los diferentes puntos sobre 10 de las 12 bandas de la imagen.

3.4. Resultados.

En cuanto a los resultados obtenidos, una vez realizada la clasificación por pixel, se vio que, en determinadas especies debido sobre todo a posicionamientos de sombra sobre las copas de los árboles, podían ser clasificados de diferentes especies un mismo árbol, es por ello que para solventarlo, se establecen teselas de 20x20 metros donde la especie que más superficie ocupe será la predominante.

Para la realización del QC se utilizará la matriz de confusión y el índice Kappa.

La matriz de confusión nos permite comparar el resultado de la clasificación con el conjunto de datos de referencia. Las muestras de referencia/validación están en filas mientras que los datos de clasificación están en columnas. Es equivalente a una matriz de contingencia. Los elementos diagonales corresponden a píxeles (o áreas) correctamente clasificados, mientras que todos los otros valores son clasificaciones erróneas, llamados confusiones.

	1	2	3	4	5	6	7	8	9	10	11
1	12234	145	70	35	171	43	94	62	24	464	106
2	244	34233	145	67	244	158	99	17	118	38	118
3	33	68	10767	18	138	19	13	44	45	36	337
4	29	167	100	18868	118	69	57	19	40	40	29
5	11	17	36	41	19497	173	37	110	33	12	49
6	18	10	33	14	208	9531	34	13	8	11	33
7	266	233	114	144	135	98	10911	34	27	57	68
8	26	54	71	24	203	30	35	8525	22	18	48
9	19	107	51	15	33	34	7	8	5662	7	37
10	15	7	6	10	7	10	8	8	17	739	11
11	7259	11692	34690	293	899	308	731	1244	436	1809	469503

Tabla 1. Matriz de confusión donde 1 representa la especie de pinos, 2 falso platanero, 3 arces, 4 olmos, 5 acacias, 6 falsas acacias, 7 almeceas, 8 aligustres, 9 castaños, 10 encinas, 11 otros.

Con la realización de la matriz de confusión, se crean a su vez una serie de índices muy orientativos respecto a la clasificación. Como se puede observar en la tabla 1, aparecen representados todos los puntos extraídos con la herramienta *sample extraction*, y son estos los utilizados para realizar la clasificación, teniendo en las columnas y las filas las diferentes clases y cuánto ha variado la clasificación entre ellas, observando una amplia mayoría de puntos bien clasificados en función a la clasificación previa dada como área de entrenamiento.

Este primer índice ofrece una visión general de la precisión global de la clasificación. No refleja la diferencia del número de muestras entre clases. El índice Kappa se extraerá en función a las áreas de entrenamiento hechas previamente, ya que son de una alta fiabilidad porque fueron hechas a mano por un fotointérprete.

El índice de kappa responde más eficazmente a este desequilibrio frecuente, utilizando un ajuste estadístico. En ambos casos el resultado es un valor comprendido entre 0 y 1, cuanto más se acerca a 1 más eficiente es la clasificación.

El índice Kappa:

$$\kappa = \frac{N \sum_{i=1}^m x_{ii} - \sum_{i=1}^m x_{i\bar{i}} x_{\bar{i}i}}{N^2 - \sum_{i=1}^m x_{i\bar{i}} x_{\bar{i}i}}$$

m = número total de clases.
N = número total de píxeles en las m clases de referencia.
x_{ii} = elementos de la diagonal de la matriz de confusión.
x_{i \bar{i}} = suma de los píxeles de la clase i de referencia.
x _{\bar{i} i} = suma de los píxeles clasificados como la clase i.

Para ello, se utilizarán como referencia los puntos que se obtuvieron en el proceso de clasificación por píxel, en concreto tras el paso de la utilización de la herramienta de *sample extraction* con la que se cribaron los puntos obtenidos aleatoriamente dentro de las propias áreas de entrenamiento. Con ello veremos la bondad del algoritmo en esta imagen comparando las áreas de entrenamiento con los resultados obtenidos.

<i>Especie detectada</i>	<i>Detección Total</i>	<i>Detectado</i>	<i>Porcentaje de acierto</i>
<i>Pino (Pinus pinea)</i>	13446	1234	90.99%
<i>Plataneros (Platanus hispanica)</i>	35478	34233	96.48%
<i>Arces (Hacer monspessulanum)</i>	11515	10767	93.05%
<i>Olmos (Ulmus minor)</i>	19534	18868	96.59%
<i>Acacias (Albizia julibrissin)</i>	20014	19497	97.42%
<i>Falsas acacias (Robinia pseudoacaia)</i>	9909	9531	96.19%
<i>Almeces (Celtis australis)</i>	12084	10911	90.19%
<i>Aligustres (Ligustrum lucidum)</i>	9054	8525	94.15%
<i>Castaños (Castanea sativa)</i>	5978	5662	94.71%
<i>Encinas (Quercus ilex)</i>	836	739	88.40%
<i>Resto de especies</i>	528862	469503	88.78%

Tabla 2. Especies detectadas, tras el QC y detectadas automáticamente, con el porcentaje de acierto.

Pueden parecer valores muy elevados, pero siempre hay que tener en cuenta, que este tipo de evaluación se hace siempre sobre los propios datos de entrada, es decir, de las áreas de entrenamiento, áreas que han sido escogidas y delimitadas de manera muy cautelosa.

3.5. Entregables.

A continuación, se muestran los entregables con una breve explicación de los mismos.

- *EsAytMadridOt2023VegTipEsp.tif*; detección de especies con el algoritmo propio de COTESA en formato raster.
- *EsAytMadridOt2023VegTipEsp_tif.xml*; metadatos del archivo raster.
- *EsAytMadridVe2023VegTipEsp.shp*; detección de especies con el algoritmo propio de COTESA en formato shapefile.
- *EsAytMadridOt2023VegTipEsp_shp.xml*; metadatos del archivo shapefile.
- *EsAytMadridOt2023VegInf.pdf*; documentación con los procedimientos seguidos en la creación de la detección de especies.