

Estrategia para la verificación de declaraciones PAC a partir de imágenes Sentinel-2 en Navarra

González-Audicana, M. ^{*}1, López, S.¹, Sola, I. ², Álvarez-Mozos, J. ¹

¹ Departamento de Ingeniería, Escuela Técnica Superior de Ingeniería Agronómica y Biociencias, Universidad Pública de Navarra, Campus Arrosadía s/n, Pamplona. España.

² LURSAREA, Observatorio Territorial de Navarra, NASUVINSA, Avenida San Jorge, 8, Pamplona, España.

Resumen: En junio de 2018, la Comisión Europea aprobó una modificación de la Política Agraria Común (PAC) que, entre otros aspectos, plantea el uso de imágenes del programa Copernicus para verificar que las declaraciones presentadas por los agricultores son correctas. En los últimos años distintas iniciativas investigadoras han tratado de desarrollar herramientas operativas con este fin, entre estas se encuentra el proyecto Interreg-POCTEFA PyrenEOS. En este artículo se expone la estrategia metodológica propuesta en el proyecto PyrenEOS, que se basa en la identificación del cultivo más probable utilizando el algoritmo Random Forests. Como elemento diferenciador, se propone seleccionar la muestra de entrenamiento a partir de una selección de las declaraciones PAC según su NDVI. Además, se definen una serie de reglas para determinar el grado de incertidumbre en la clasificación y los criterios para categorizar cada recinto del mapa de verificación según un código de colores a modo de semáforo, en el que el *verde* indica recintos con declaración correcta, el *rojo* recintos con declaración dudosa y el *naranja* recintos con una incertidumbre alta en la clasificación. Esta estrategia de verificación se aplica a dos Comarcas Agrarias de Navarra, en una campaña agrícola para la que se contó con inspecciones de campo de aproximadamente el 7% de los recintos declarados. Los resultados de esta validación, con fiabilidades globales en la clasificación próximas al 80% cuando se considera el cultivo más probable predicho por el clasificador y al 90% cuando se consideran los dos cultivos más probables, ponen de manifiesto que es posible identificar los recintos correctamente declarados (recintos *verdes*) con una tasa de error inferior al 1%. Los recintos *naranjas* y *rojos*, que requerirán del análisis y juicio posterior de técnicos de inspección, suponen un porcentaje reducido de las declaraciones (~6% de los recintos) y concentran la mayoría de las declaraciones incorrectas.

Palabras clave: PAC, monitorización Sentinel-2, verificación declaraciones, inspecciones de campo.

A strategy for the verification of CAP declarations using Sentinel-2 images in Navarre

Abstract: In June 2018, the European Commission approved a modification of the Common Agricultural Policy (CAP) that, among other measures, proposed the use of Copernicus data for the verification process of farmers' declarations. In recent years, several research efforts have been conducted to develop operational tools to accomplish this aim, among this the Interreg-POCTEFA PyrenEOS project. This article describes the methodological strategy proposed in the PyrenEOS project, which is based on the identification of the most probable crop using the Random Forests algorithm. Originally, the strategy builds a training sample from the CAP declarations file

To cite this article: González-Audicana, M., López, S., Sola, I., Álvarez-Mozos, J. 2020. A strategy for the verification of CAP declarations using Sentinel-2 images in Navarre. *Revista de Teledetección*, 56, 69-88. <https://doi.org/10.4995/raet.2020.14128>

* Corresponding author: maria.audicana@unavarra.es

based on their NDVI time series. In addition, a series of rules are proposed to establish the level of uncertainty in the classification, and the criteria used to represent each parcel in the verification map with a simple colour coding (traffic light), where green represents correctly declared parcels, red indicates that the declaration is dubious, and orange corresponds to parcels with a high classification uncertainty. This verification strategy has been applied to two Agricultural Regions of Navarre, during an agricultural campaign where valuable field inspections were available, with a sampling intensity of 7% of the declared parcels. The results obtained, report overall accuracies close to 80% when the most probable crop was considered, and 90% when the two most probable crops were considered. This proves it is possible to identify correctly declared parcels (green parcels) with an error below 1%. Orange and red parcels should be considered for further analysis and inspection by technicians from the paying agencies, though they represent a small percentage of declarations (~6% of parcels), and include most of the wrong declarations.

Key words: CAP (Common Agricultural Policy), Sentinel-2 monitoring, On The Spot Check (OTSC).

1. Introducción

El conocimiento de los usos del suelo, así como de las cubiertas vegetales y/o cultivos presentes en el mismo es una información básica para una gestión adecuada del territorio (Koschke et al., 2012), no sólo a nivel local sino que también desde una perspectiva global, con implicaciones tanto en la producción de alimentos y materias primas como en otros servicios ecosistémicos como la biodiversidad y preservación de hábitats, los recursos hídricos, la calidad del aire, el secuestro de carbono o el control de la expansión de enfermedades infecciosas (Foley et al., 2005).

En el contexto agrícola europeo, la Política Agraria Común (PAC), con un presupuesto que ronda el 30% del presupuesto total de la Unión Europea, establece distintos instrumentos de financiación e incentivos que determinan en mayor o menor medida los cultivos y cubiertas implantados en gran parte del continente, así como las técnicas de manejo empleadas y su productividad (Rizov et al., 2013). Para beneficiarse de estas ayudas, los agricultores deben declarar año a año los cultivos implantados en sus parcelas. Las Agencias Pagadoras de cada país tienen el deber de verificar que las declaraciones sean correctas, lo que hasta la fecha se ha realizado mediante inspecciones en campo de una muestra de las declaraciones (típicamente en torno al 5%) o en los últimos años mediante fotointerpretación de ortofotografías aéreas o imágenes satelitales de muy alta resolución espacial (Devos y Kay, 2011).

El 1 de junio de 2018 la Comisión Europea presentó una iniciativa legislativa para modificar la PAC que será de aplicación en el periodo 2021-2027 (Reglamento de Ejecución (UE) 2018/746). Entre otras modificaciones (Hogan, 2018), se plantea que los procesos de verificación de las declaraciones se realicen utilizando las observaciones adquiridas por los satélites Sentinel del programa Copernicus (Devos et al., 2018a; 2018b). Esta medida se apoya en la madurez tecnológica alcanzada en los últimos años en el ámbito de la clasificación digital de imágenes satelitales (Maxwell et al., 2018). No en vano, se considera que el programa Copernicus ha revolucionado este campo de estudio debido a su equilibrado compromiso entre la resolución espacial, espectral y temporal de sus adquisiciones (Gascon et al., 2017), la libre difusión de sus imágenes como productos de nivel 2A (Louis et al., 2019) ya listos para su uso y la generalización de herramientas de clasificación maduras (Chakhar et al., 2020), basadas muchas de ellas en técnicas de aprendizaje automático (Maxwell et al., 2018), disponibles en entornos libres tanto en modo local como en la nube (Shelestov et al., 2017).

Hasta la fecha, la alternativa metodológica que ha producido mejores resultados ha sido la clasificación de observaciones multispectrales Sentinel-2 que, en igualdad de condiciones, han demostrado una mayor capacidad de discriminar cultivos y cubiertas vegetales que las observaciones radar Sentinel-1 (Velooso et al., 2017, Van Tricht et al., 2018). El uso combinado de ambos tipos de imágenes ha demostrado reportar beneficios adicionales (Van Tricht et al., 2018; Orynbaikyzy et al., 2019),

pero de momento las observaciones Sentinel-1 no se distribuyen aun como productos de nivel 2 y su tratamiento requiere de varios procesos que dificultan su integración en cadenas operativas de generación de servicios (Amitrano et al., 2019).

En lo que respecta a los algoritmos de clasificación, predominantemente se ha optado por algoritmos de tipo supervisado, por la dificultad asociada a la interpretación de las clases generadas en los no supervisados (Chuvieco y Huete, 2010). En concreto, los algoritmos basados en técnicas de aprendizaje automático (ML del inglés *Machine Learning*) de distinto tipo han demostrado un rendimiento superior a otros algoritmos clásicos de tipo probabilístico o a otras estrategias como los clasificadores expertos (Chakhar et al., 2020). La disponibilidad de series temporales densas de imágenes posibilita la implementación de algoritmos de clasificación basados en la similitud temporal de los elementos a clasificar (sean píxeles u objetos) (Petitjean et al., 2012). Sin embargo, se ha visto que las clasificaciones realizadas con algoritmos ML basados en una serie relativamente reducida de observaciones adquiridas en momentos clave del ciclo de desarrollo de los cultivos proporciona resultados similares de forma más eficiente (Belgiu y Csillik, 2018; Van Tricht et al., 2018), al menos en regiones del mundo con una estacionalidad marcada, como el continente europeo. Algoritmos basados en árboles de decisión como C5 (Quinlan, 1996) o *Random Forests* (Breiman, 2001) han demostrado ser herramientas fiables y estables (Boryan et al., 2011; Belgiu y Dragut, 2016), como también otros basados en redes neuronales y su versión profunda (Maggiori et al., 2017). Sin embargo, estos últimos requieren de un mayor entrenamiento y son más costosos computacionalmente (Jin et al., 2017). Entre las cualidades más interesantes de los algoritmos de clasificación ML para aplicaciones de clasificación de cultivos están: la capacidad de conocer no sólo la clase predicha sino la incertidumbre o robustez de la predicción; la flexibilidad para trabajar con datos de naturaleza variada e incluso con una proporción no despreciable de datos perdidos; la capacidad de optimización de sus parámetros de ajuste utilizando métricas internas de error; la posibilidad de analizar (también de forma interna) la importancia de las variables de entrada y de priorizarlas (Belgiu y Dragut, 2016).

Sin embargo, el reto de verificar de forma operativa las declaraciones PAC de más de ciento treinta millones de parcelas agrícolas en el continente europeo (European Court of Auditors, 2016) es enorme. Más si cabe teniendo en cuenta que el fin de esta verificación es que se utilice como evidencia para poder iniciar procesos punitivos contra los eventuales infractores. Es por ello que en los últimos años se están desarrollando diversas iniciativas investigadoras para proponer metodologías y estrategias que permitan materializar el control operativo de declaraciones a partir de imágenes remotas y conocer su grado de fiabilidad (Sitokonstantinou, et al., 2018; Defourny et al., 2019; Koetz et al., 2019). Entre estas iniciativas se encuentra el proyecto Interreg-POCTEFA PyrenEOS, recientemente finalizado, que ha trabajado en el desarrollo de varios servicios piloto basados en observaciones Sentinel en un marco transfronterizo, implicando a administraciones, empresas y organismos de investigación de Euskadi, Navarra y el Departamento de Pirineos Atlánticos (Francia). En esta zona relativamente pequeña, la gran diversidad climática hace que se desarrollen sistemas agrícolas muy distintos. Por otro lado, la orografía ha dado lugar a un paisaje rural conformado por parcelas pequeñas e irregulares creando un mosaico en el que las tierras agrícolas se intercalan con otros usos. Además, la persistente cobertura nubosa de algunas zonas puede comprometer la disponibilidad de imágenes. Por todo esto se considera que esta zona de estudio puede ser un buen marco para testar estrategias de verificación y control a partir de imágenes Sentinel y conocer sus limitaciones y posibles áreas de mejora.

En este artículo se detalla la estrategia metodológica implementada en el marco del proyecto PyrenEOS para la verificación de declaraciones PAC, y se muestran los resultados obtenidos al realizar una evaluación completa de la misma, identificando eventuales áreas de mejora. Para ello, el artículo se centra en dos comarcas agrarias contrastantes (en cuanto a climatología y tipos de cultivos) y en una campaña agrícola para la que se contó con inspecciones de campo valiosas para evaluar la fiabilidad de los resultados obtenidos. En los siguientes apartados se desarrolla en detalle la metodología seguida, se describen los resultados obtenidos y se apuntan las principales conclusiones y líneas futuras de trabajo.

2. Zona de estudio

El estudio se centra en dos de las siete Comarcas Agrarias en las que se divide Navarra, en concreto, en las Comarcas III, correspondiente a la zona de la cuenca de Pamplona y la VI, correspondiente a la Ribera Alta (Figura 1). La Comarca Agraria III (CA-III) se caracteriza por tener un clima de transición entre Oceánico y Mediterráneo, con una precipitación media anual en torno a los 900 mm y una temperatura media de aproximadamente 12 °C, lo que favorece el desarrollo de cultivos herbáceos en secano, principalmente cereales. La Comarca VI (CA-VI) tiene un clima Mediterráneo, con una precipitación media anual mucho menor, de unos 350 mm y una temperatura media de 14 °C. La diversidad de cultivos en esta comarca es mucho mayor ya que además de cultivos herbáceos de secano, hay una extensión importante dedicada a cultivos herbáceos en regadío, así como a cultivos leñosos como viñedos y frutales.



Figura 1. Comarcas Agrarias de Navarra (fuente: IDENA – Gobierno de Navarra).

3. Materiales y Métodos

3.1. Declaraciones e inspecciones PAC

Durante los meses de abril-mayo de cada campaña, el Departamento de Desarrollo Rural y Medio Ambiente (DRyMA) del Gobierno de Navarra

tramita todas las solicitudes de ayudas PAC que presentan los agricultores, generando un fichero vectorial con la información geográfica y alfanumérica de cada recinto declarado. En el caso de la campaña de 2017, este fichero contiene 332029 recintos, correspondientes a una superficie total declarada de casi 400000 ha, de los que 25177 corresponden a la CA-III y 56814 a la CA-IV, con una superficie declarada de 36375 ha y 77329 ha, respectivamente.

El fichero de declaraciones PAC de la campaña 2017 recoge 148 cultivos/ usos del suelo diferentes. Los cultivos declarados se reagruparon en 29 clases, en base a criterios de similitud morfológica y fenológica, atendiendo a la importancia relativa de cada cultivo, en términos de superficie cultivada y de interés desde el punto de vista de las subvenciones PAC, siguiendo las recomendaciones del Departamento de DRyMA. En la Tabla 1 se muestran las clases o cultivos agrupados de la campaña 2017, indicándose, para cada uno de ellos, el número de recintos declarados, la superficie total declarada y el tamaño medio de recinto en las dos Comarcas Agrarias consideradas.

En la CA-III predominan los cereales en secano, que suponen el 60% de la superficie declarada, seguidos de los pastos, que corresponden al 20% de la superficie. En la CA-VI los cereales representan el 40% de la superficie declarada y los pastos, cerca del 16%. Los cultivos de verano como el maíz, la alfalfa, el tomate o los hortalizas de verano corresponden cerca del 15% de la superficie declarada, y los cultivos permanentes como la viña, frutales, almendros y olivos adquieren mayor importancia en esta comarca, con un 12% de la superficie declarada.

Una vez tramitadas las declaraciones PAC, el Servicio de Inspecciones del Departamento de DRyMA del Gobierno de Navarra llevó a cabo, durante los meses de junio, julio y agosto de 2017, la campaña de inspecciones en campo, verificando *in situ* una muestra de los recintos declarados. En las CA-III y CA-VI se inspeccionaron 1126 y 4316 recintos, respectivamente, lo que supone el 4,5% y 7,6% de los recintos declarados en ambas comarcas, y el 4,8% y 8% de la superficie declarada, respectivamente. En la Tabla 2 se muestran, para cada clase, el número de recintos inspeccionados, la superficie inspeccionada y el tamaño medio de recinto inspeccionado en las CA-III y CA-VI.

Tabla 1. Recintos declarados en las comarcas CA-III y CA-VI en la campaña 2017.

CULTIVO	Comarca Agraria III				Comarca Agraria VI			
	Nº recintos	Superficie (ha)	Superficie (%)	Superficie media (ha)	Nº recintos	Superficie (ha)	Superficie (%)	Superficie media (ha)
Alfalfa	37	32	7,3	0,86	1541	1805	27,4	1,17
Almendros	37	13	3,0	0,36	591	407	6,2	0,69
Arroz	-	-	-	-	616	872	13,3	1,42
Avena	2140	3497	795,6	1,63	961	1778	27,0	1,85
Barbecho	1076	794	180,5	0,74	6552	8673	131,8	1,32
Cebada	4518	7483	1702,3	1,66	11042	20043	304,5	1,82
Colza	521	897	204,1	1,72	73	206	3,1	2,83
Espárragos	59	89	20,3	1,52	644	446	6,8	0,69
Frutales	330	72	16,3	0,22	2161	1050	16,0	0,49
Girasol	269	625	142,1	2,32	100	213	3,2	2,13
Guisante	472	848	193,0	1,80	519	1270	19,3	2,45
Habas	557	862	196,1	1,55	81	102	1,5	1,25
Hortícola de invierno	133	41	9,2	0,30	1774	1191	18,1	0,67
Hortícola de verano	-	-	-	-	1600	1098	16,7	0,69
Maiz	298	715	162,7	2,40	3059	5765	87,6	1,88
Mezclas con cereal	39	130	29,7	3,34	133	166	2,5	1,25
Olivar	233	233	52,9	1,00	1810	1134	17,2	0,63
Otras leguminosas	7	5	1,1	0,69	28	128	1,9	4,57
Otros cultivos herbáceos	30	54	12,2	1,79	327	489	7,4	1,50
Otros cultivos permanentes	85	45	10,2	0,53	283	122	1,9	0,43
Pastos arbolados	166	388	88,4	2,34	94	275	4,2	2,92
Pastos arbustivos	4175	4070	925,8	0,97	5316	6524	99,1	1,23
Pastos herbáceos	2585	2612	594,3	1,01	4436	5727	87,0	1,29
Patata	28	18	4,1	0,65	120	115	1,8	0,96
Superficies forestales	359	1029	234,1	2,87	636	1461	22,2	2,30
Tomate	-	-	-	-	359	847	12,9	2,36
Trigo	6549	11147	2535,8	1,70	5912	8577	130,3	1,45
Veza	197	236	53,7	1,20	216	264	4,0	1,22
Viña	277	440	100,0	1,59	5830	6581	100,0	1,13
TOTAL	25177	36375		1,40	56814	77329		1,54

Señalar que la selección de la muestra de recintos a inspeccionar que se realiza cada campaña no sigue un criterio estadístico de representatividad del archivo de declaraciones (Olofsson et al., 2014), sino que está orientada a detectar casos potencialmente conflictivos. Esto supone que la distribución de probabilidad de los cultivos en los recintos declarados y en los recintos inspeccionados no sea exactamente igual, y que en la campaña de 2017 haya algunas clases, en general con poca presencia en el territorio, para las que no haya ningún recinto inspeccionado (Tabla 2). Es el caso de las clases *otras leguminosas*, *otros cultivos herbáceos*, *otros cultivos permanentes* o *superficies forestales* en la CA-III y de las clases *colza*, *habas* y *otros cultivos permanentes* en la CA-VI, que suponen únicamente el 1,14% y el 0,77%, respectivamente, de los recintos declarados en ambas comarcas.

Además, tal y como se observa en la Figura 2, la distribución geográfica de los recintos inspeccionados no sigue la misma pauta que la de los recintos declarados, ya que como se ha comentado previamente, la selección de muchos de estos recintos está dirigida a detectar posibles casos conflictivos.

3.2. Imágenes Sentinel-2

Para poder cubrir todo el territorio de Navarra, es necesario trabajar con 4 de los *tiles* correspondientes a la órbita 94 de los satélites Sentinel-2 (30TXN, 30TXM, 30TWN y 30TWM). Aunque con el lanzamiento del satélite Sentinel-2B la frecuencia de adquisición de imágenes se redujo a 5 días, en zonas con un porcentaje importante de días moderada o totalmente nublados como Navarra, la disponibilidad de imágenes Sentinel-2

Tabla 2. Recintos inspeccionados en las comarcas CA-III y CA-VI en la campaña 2017.

CULTIVO	Comarca Agraria III				Comarca Agraria VI			
	Nº recintos	Superficie (ha)	Superficie (%)	Superficie media (ha)	Nº recintos	Superficie (ha)	Superficie (%)	Superficie media (ha)
Alfalfa	37	32	7,3	0,86	1541	1805	27,4	1,17
Almendros	37	13	3,0	0,36	591	407	6,2	0,69
Arroz	-	-	-	-	616	872	13,3	1,42
Avena	2140	3497	795,6	1,63	961	1778	27,0	1,85
Barbecho	1076	794	180,5	0,74	6552	8673	131,8	1,32
Cebada	4518	7483	1702,3	1,66	11042	20043	304,5	1,82
Colza	521	897	204,1	1,72	73	206	3,1	2,83
Espárragos	59	89	20,3	1,52	644	446	6,8	0,69
Frutales	330	72	16,3	0,22	2161	1050	16,0	0,49
Girasol	269	625	142,1	2,32	100	213	3,2	2,13
Guisante	472	848	193,0	1,80	519	1270	19,3	2,45
Habas	557	862	196,1	1,55	81	102	1,5	1,25
Hortícola de invierno	133	41	9,2	0,30	1774	1191	18,1	0,67
Hortícola de verano	-	-	-	-	1600	1098	16,7	0,69
Maiz	298	715	162,7	2,40	3059	5765	87,6	1,88
Mezclas con cereal	39	130	29,7	3,34	133	166	2,5	1,25
Olivar	233	233	52,9	1,00	1810	1134	17,2	0,63
Otras leguminosas	7	5	1,1	0,69	28	128	1,9	4,57
Otros cultivos herbáceos	30	54	12,2	1,79	327	489	7,4	1,50
Otros cultivos permanentes	85	45	10,2	0,53	283	122	1,9	0,43
Pastos arbolados	166	388	88,4	2,34	94	275	4,2	2,92
Pastos arbustivos	4175	4070	925,8	0,97	5316	6524	99,1	1,23
Pastos herbáceos	2585	2612	594,3	1,01	4436	5727	87,0	1,29
Patata	28	18	4,1	0,65	120	115	1,8	0,96
Superficies forestales	359	1029	234,1	2,87	636	1461	22,2	2,30
Tomate	-	-	-	-	359	847	12,9	2,36
Trigo	6549	11147	2535,8	1,70	5912	8577	130,3	1,45
Veza	197	236	53,7	1,20	216	264	4,0	1,22
Viña	277	440	100,0	1,59	5830	6581	100,0	1,13
TOTAL	25177	36375		1,40	56814	77329		1,54

libres de nubes es limitada. En la Figura 3 se observa cómo las imágenes libres de nubes son escasas (10 imágenes con una superficie libre de nubes superior al 90% durante todo 2017), aunque estas se distribuyeron de forma más o menos uniforme a lo largo de toda la campaña, salvo en el periodo comprendido entre el 19/04/2017 y el 18/06/2017, importante *a priori* para el seguimiento de cultivos de invierno, principalmente cereales.

En este trabajo se descargaron únicamente las imágenes con una superficie libre de nubes superior al 40% en el conjunto de los cuatro *tiles*, que se procesaron a nivel 2A con el *toolbox* SEN2COR de SNAP (Louis et al., 2019), aplicando tanto la corrección atmosférica como topográfica. Para cada fecha, se mosaicaron los cuatro *tiles*, se calculó el índice de vegetación NDVI y, partiendo de la capa *Quality Scene Classification* generada por SEN2COR, se enmascararon las áreas cubiertas

por nubes y sombras de nubes, asignando un valor nulo a los píxeles correspondientes a estas áreas.

3.3. Datos Sentinel-2 a nivel de recinto declarado

Para cada recinto declarado se calculó el valor medio de reflectancia en superficie en las bandas 2 a 8, 8A, 11 y 12, así como el de NDVI. Para evitar el efecto borde, se consideraron en el cálculo únicamente los píxeles cuyo centroide se encontraba dentro del polígono resultante de aplicar un buffer interior de 5 m a cada recinto. Teniendo en cuenta que se trabajó con 39 imágenes mosaicadas y enmascaradas y que en cada fecha se calcularon los valores de reflectancia media en 10 bandas espectrales más un índice de vegetación, el número de variables consideradas para caracterizar el comportamiento espectral y temporal de cada recinto

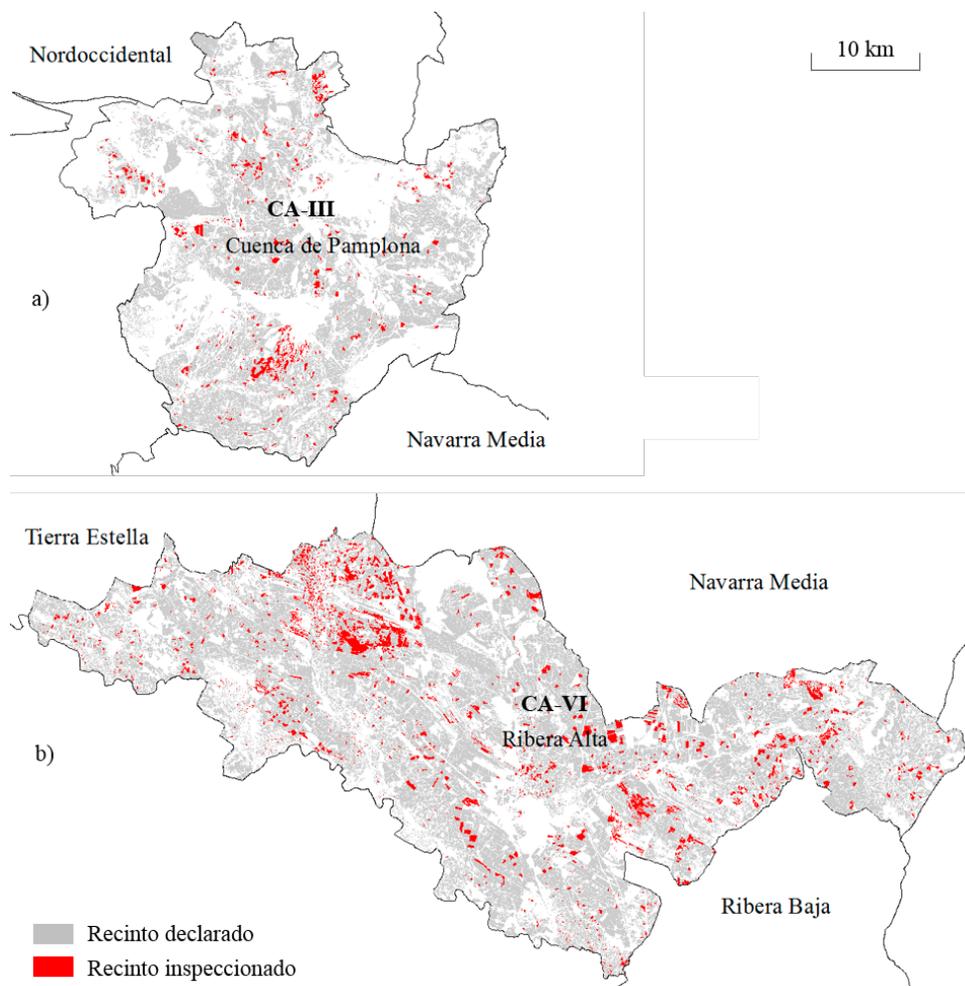


Figura 2. Recintos declarados e inspeccionados en las CA-III y CA-VI en la campaña 2017.

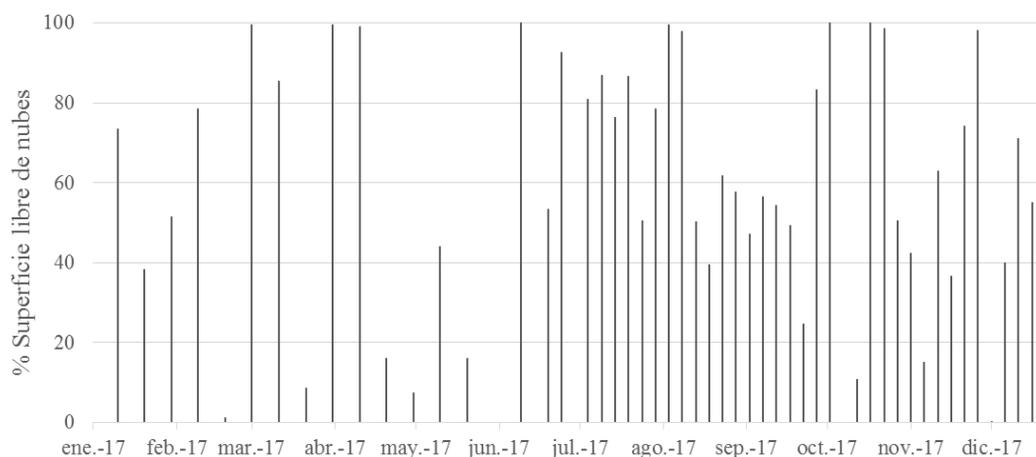


Figura 3. Porcentaje de superficie libre de nubes en las imágenes Sentinel-2 captadas en 2017 correspondientes a los cuatro tiles que cubren Navarra.

declarado fue de 429. Es importante señalar que en aquellos recintos y fechas en los que la observación estuvo afectada por nubes o sombras de nubes, los valores de estas variables fueron nulos. Para tener este aspecto en cuenta, se determinó, para cada recinto, el número de datos no nulos disponibles.

Antes de pasar a la fase de clasificación, se eliminaron los recintos con cero datos no nulos, es decir, recintos que por su reducido tamaño y/o forma alargada no incluyen el centroide de ningún píxel Sentinel-2 y que, por lo tanto, no se pueden monitorizar ni verificar a partir de información derivada de estas imágenes. En la CA-III se eliminaron 1305 recintos y en la CA-VI, 1887, lo que supuso el 5,18% y el 3,32%, respectivamente, de los recintos declarados y menos del 0,2% de la superficie declarada en ambas comarcas.

3.4. Clasificación de los recintos declarados

Tal y como se ha apuntado previamente, la estrategia propuesta en el marco del proyecto PyrenEOS basa el control de verificación en la identificación del cultivo o cultivos más probables en cada recinto declarado, a través de la clasificación supervisada de los mismos. El clasificador que se utilizó en este caso fue el algoritmo de aprendizaje automático conjunto *Random Forests* (RF) (Breiman, 2001). Para entrenar el clasificador se generó una muestra de entrenamiento a partir del fichero de declaraciones PAC, seleccionando aquellos recintos más representativos de cada clase. Esta selección se llevó a cabo en tres fases: a) cálculo de la curva temporal media de NDVI de cada clase en el periodo de tiempo considerado, utilizando todos los recintos declarados; b) cálculo del error cuadrático medio (RMSE) de la curva temporal de NDVI de cada recinto respecto a la curva temporal media de NDVI de la clase declarada para ese recinto y c) selección, para cada clase, de los recintos con menor RMSE según un porcentaje de depuración establecido. Teniendo en cuenta que la clasificación se realiza de forma estratificada, por comarca agraria, y con el fin de disponer de suficiente muestra de entrenamiento en todas las clases, se decidió aplicar un porcentaje de depuración del 10%. Esto implica que en cada comarca agraria se seleccionaron como muestra de entrenamiento el 90% de los recintos con menor RMSE para cada clase. Para definir

este umbral de depuración se tuvo en cuenta que el porcentaje de recintos inspeccionados en campo en los que el cultivo declarado no coincidía con el observado *in situ* era inferior al 5,5%, por lo que el valor del 10% garantizaba, *a priori*, no utilizar recintos incorrectamente declarados para entrenar el clasificador. Además, se eliminaron del fichero de entrenamiento todos los recintos que se inspeccionaron en campo (muestra de validación), con el fin de realizar una evaluación de resultados que reflejara la fiabilidad real de la clasificación. Por último, se eliminaron del fichero de entrenamiento los recintos correspondientes a aquellas clases que, en cada comarca agraria, no contaran con al menos 30 recintos declarados. Por lo tanto, en la CA-III la leyenda quedó definida por 24 clases y en la CA-VI por 29.

Una vez definida la muestra de entrenamiento, se aplicó el algoritmo de clasificación RF, implementado utilizando la librería *Scikit-learn* de Python (Pedregosa et al., 2011) a la totalidad de los recintos declarados en las CA-III y CA-VI. Este algoritmo genera un número elevado de árboles de decisión automáticos (*n_estimators*) a partir de submuestras del conjunto de datos de entrenamiento tomadas de forma aleatoria y con reemplazo. Cada árbol se construye mediante la división sucesiva de su conjunto de datos según la variable que maximiza el criterio de impureza de Gini de entre un subconjunto de las variables predictivas (*max_features*) obtenido de forma aleatoria. En la fase de predicción, cada recinto es clasificado por cada árbol de forma independiente, asignándose a la clase final por mayoría. El clasificador permite obtener como salida no sólo la clase asignada a cada recinto, sino que también es posible conocer su porcentaje de voto y el porcentaje de voto otorgado al resto de clases. Esto resulta interesante ya que permite estimar la robustez de la clasificación para cada recinto.

Los parámetros *n_estimators*, *max_features* y la profundidad del árbol (*max_depth*), se optimizaron evaluando la fiabilidad de la clasificación y su coste computacional mediante una estrategia de validación cruzada en 4 particiones del archivo de entrenamiento. Tras la optimización se seleccionó un número de árboles (*n_estimators*) de 300, un tamaño de subconjunto de variables predictivas (*max_features*) de 20 y una profundidad máxima (*max_depth*) de 40.

Teniendo en cuenta que la diferencia en el número de recintos de entrenamiento entre las clases mayoritarias y minoritarias es importante y que este hecho repercute en la fiabilidad del clasificador RF (Mellor et al., 2015), se decidió equilibrar las muestras utilizando la opción de balanceado que proporciona la función *RandomForestClassifier* de Python, que asigna mayores pesos a las clases minoritarias.

Como resultado del clasificador RF se obtuvo, para cada recinto declarado, la siguiente información: la predicción de la primera y segunda clase más probables, así como su porcentaje de voto. Los datos de porcentaje de voto se utilizaron para estimar el grado de incertidumbre de la clasificación de cada recinto, que se categorizó en tres niveles: alto, medio y bajo según las siguientes reglas, que se ejecutan de modo que las últimas prevalecen frente a las primeras:

```

if %voto_pred1 ≥ 0.5 then
    INCERTIDUMBRE = baja
if (0.3 < %voto_pred1 < 0.5) and
    (%voto_pred1 - %voto_pred2) ≥ 0.2 then
    INCERTIDUMBRE = baja
if (0.3 < %voto_pred1 < 0.5) and
    (%voto_pred1 - %voto_pred2) < 0.2 then
    INCERTIDUMBRE = media
if %voto_pred1 ≤ 0.3 then
    INCERTIDUMBRE = alta
if %voto_pred2 ≥ 0.25 then
    INCERTIDUMBRE = baja
    
```

donde *%voto_pred1* y *%voto_pred2* representan el porcentaje de voto de la primera y segunda clase más probables, respectivamente.

Los umbrales a aplicar en las reglas anteriores se optimizaron utilizando los datos recopilados en las inspecciones de campo de la campaña 2016 de todo Navarra y son los mismos para todas las Comarcas Agrarias.

3.5. Mapa de verificación de declaraciones

Realizada la clasificación, es conveniente generar un mapa de verificación de declaraciones que represente, de forma gráfica, el nivel de acuerdo entre el cultivo declarado por el agricultor y la predicción del clasificador para cada recinto declarado. Los niveles de acuerdo considerados en este trabajo se agrupan en tres casos posibles que se representan con la siguiente leyenda de colores: a) *verde*, cuando se considera que la declaración es correcta; b) *naranja*, cuando se considera que la clasificación y por lo tanto la predicción de cultivos es dudosa y c) *roja* cuando se considera que la declaración puede ser dudosa. Para establecer a qué caso corresponde cada recinto se establecen los siguientes criterios, resumidos en la Figura 4:

```

if (class_decl = class_pred1 or
    class_decl = Class_pred2) and
    (INCERTIDUMBRE = baja or
    INCERTIDUMBRE = media) then
    VERIFICACION = verde
if (class_decl ≠ class_pred1 or
    class_decl ≠ class_pred2) and
    INCERTIDUMBRE = baja then
    VERIFICACION = rojo
else VERIFICACION = naranja
    
```

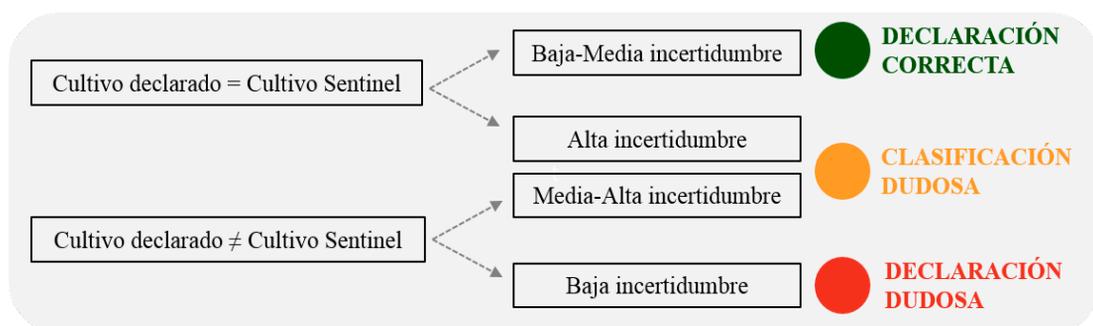


Figura 4. Definición del nivel de acuerdo entre el cultivo declarado y el predicho a partir de datos Sentinel-2.

donde *class_decl* indica la clase o cultivo declarado por el agricultor, *class_pred1* y *class_pred2* la primera y segunda clase más probable predichas por el clasificador e *INCERTIDUMBRE*, el grado de incertidumbre en la predicción asociada a cada recinto.

3.6. Validación de los resultados

La validación de los resultados para las dos comarcas objeto de estudio incluyó tanto un análisis de la fiabilidad de la clasificación RF como un análisis de la fiabilidad del mapa de verificación de declaraciones. En ambos casos se utilizó como muestra de validación el archivo de inspecciones de campo, que permite contar con muestras no utilizadas en el entrenamiento.

3.6.1. Análisis de fiabilidad de la clasificación RF

Este análisis se llevó a cabo comparando, a nivel de recinto, el cultivo observado en la inspección en campo con el primer cultivo predicho y a continuación, con el primer o segundo cultivo predicho por el clasificador. Se obtuvieron métricas de rendimiento tanto a nivel general como para cada clase. A nivel general se calculó la *Fiabilidad Global* mientras que a nivel de clase se utilizó la *Fiabilidad del Productor*, ya que en el caso que nos ocupa, se requiere determinar el grado de acuerdo entre el cultivo declarado por el agricultor y el predicho por el clasificador y no tanto un mapa temático en el que la *Fiabilidad del Usuario* podría tener más interés.

3.6.2. Análisis de fiabilidad del mapa de verificación

En este caso se compararon las declaraciones categorizadas como *verdes*, *naranjas* o *rojas* con las declaraciones definidas como correctas o incorrectas a partir de los datos de inspección en campo. Este análisis permitió determinar la *tasa de falsos verdes*, es decir, el porcentaje de recintos que se habían categorizado como correctamente declarados cuando no lo eran y la *tasa de falsos rojos*, es decir, el porcentaje de recintos que se habían categorizado como con declaración dudosa siendo esta correcta. Asimismo, permitió obtener una estimación del porcentaje de declaraciones incorrectas identificables mediante el procedimiento de trabajo establecido en el marco de este estudio.

4. Resultados y discusión

4.1. Mapa de cultivos predichos por el clasificador RF

La verificación de las declaraciones PAC se basa en la estimación del nivel de acuerdo entre el cultivo declarado por el agricultor para un recinto y el predicho por el clasificador para el mismo. En la Figura 5 se muestra el mapa que se obtiene al considerar el cultivo predicho en primer lugar por el clasificador RF para todos los recintos declarados en las CA-III y CA-VI en la campaña 2017.

Este mapa constituye el punto de partida para la verificación de las declaraciones PAC, de ahí la importancia de analizar en detalle su fiabilidad.

4.2. Análisis de fiabilidad de la clasificación RF

En la Tabla 3 se muestran los resultados de fiabilidad global obtenidos por comarca agraria al comparar, en los recintos inspeccionados, el cultivo observado en campo con el primer cultivo más probable y con los dos cultivos más probables según la predicción del clasificador. Como era de esperar, la fiabilidad de la clasificación se incrementa notablemente, en casi 10 puntos porcentuales, al considerar los dos cultivos más probables. Esto implica que en el 89,4% y el 88,3% de los recintos de las CA-III y CA-VI, respectivamente, el cultivo inspeccionado en campo coincide con el primer o segundo cultivo más probable predicho por el clasificador. Estos valores de fiabilidad se consideran satisfactorios teniendo en cuenta la diversidad de clases consideradas, y son similares o incluso mejores a los obtenidos en otros estudios realizados utilizando imágenes Sentinel-2 (e.g., Van Tricht et al., 2018; Defourny et al., 2019; Chakhar et al., 2020).

Tabla 3. Fiabilidad global de la clasificación de los recintos declarados. Validación externa con las inspecciones de campo en las comarcas agrarias CA-III y CA-VI.

Campaña 2017			
INSPECCIONES			
Comarca Agraria	Parcelas inspeccionadas	Fiabilidad clasificador 1º cultivo predicho	Fiabilidad clasificador 1º y 2º cultivo predicho
CA-III	1126	79,9	89,4
CA-VI	4316	79,7	88,3
CA-III y CA-VI	5442	79,7	88,6

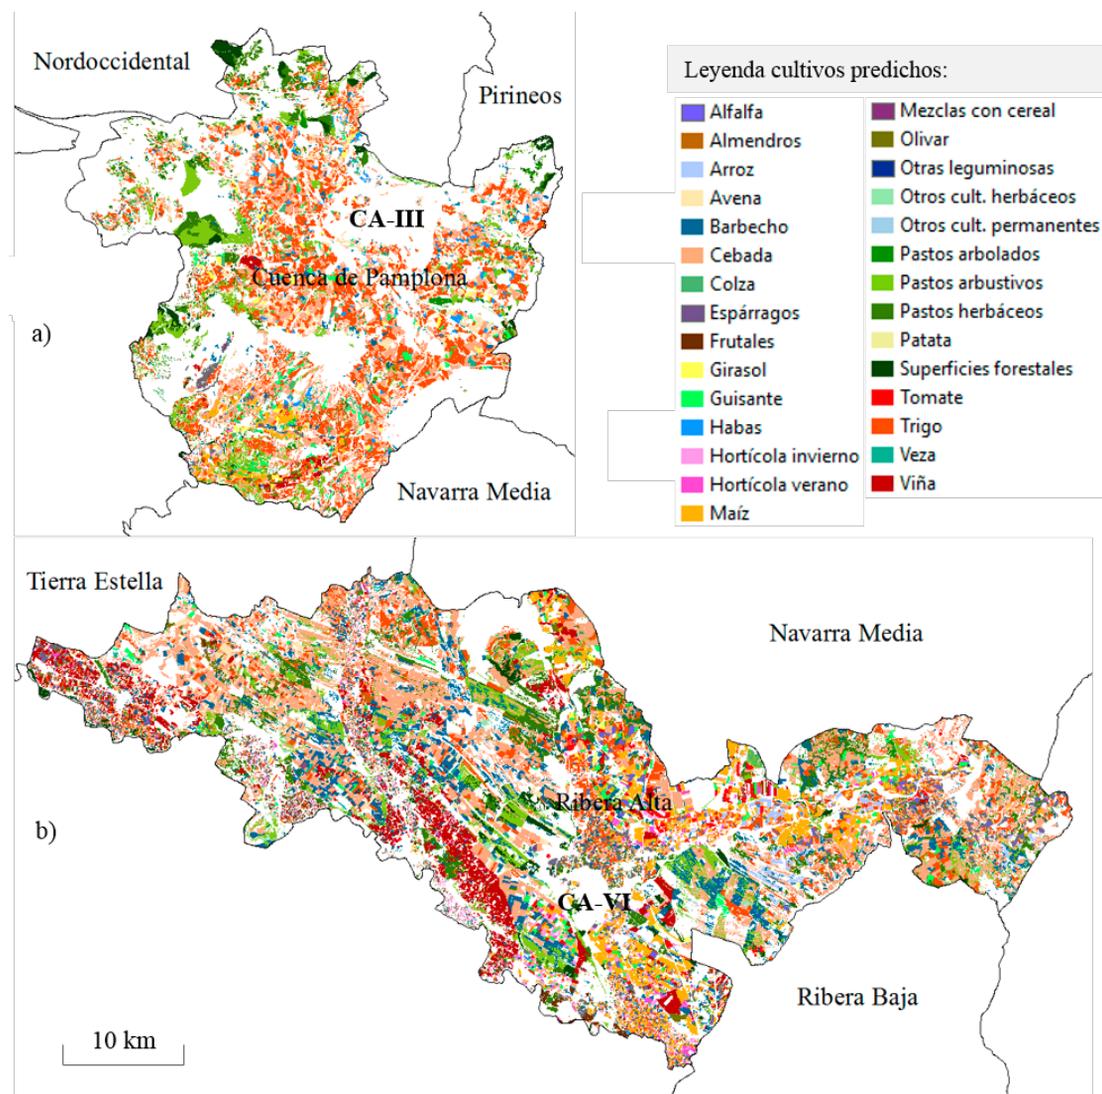


Figura 5. Mapa de cultivos generado a partir del primer cultivo predicho por el clasificador en las comarcas CA-III (a) y CA-VI (b), correspondiente a la campaña 2017.

En la Tabla 4 se muestran los valores de fiabilidad del productor por clase y por Comarca Agraria. Como se observa, las clases que tienen valores de fiabilidad del productor superiores al 80% (en verde en la Tabla 4), como *cebada*, *trigo*, *barbecho*, *maíz*, *vid*, *arroz*, *tomate*, *alfalfa*, etc., se corresponden con aquellas que cuentan con un mayor número de declaraciones y, por lo tanto, con una mayor muestra de entrenamiento. De hecho, estas clases suponen el 83,1% de los recintos declarados y el 85,6% de la superficie declarada. Por el contrario, las clases como *almendros*, *veza* o *girasol*, con menor presencia en el territorio y

por lo tanto con menor muestra de entrenamiento, así como las clases con mayor variabilidad intraclass, como *mezcla leguminosas-cereal*, *hortícola de invierno*, *otros cultivos herbáceos* o *superficies forestales*, presentan valores de fiabilidad más bajos. Conviene además señalar el caso particular de las clases *frutales* y *olivar*, cultivados en recintos con superficies medias en torno a 0,5 ha, lo que ha repercutido negativamente en su clasificación a pesar de tener una muestra de entrenamiento semejante o incluso superior a la de clases que se han clasificado con mayor fiabilidad.

Tabla 4. Fiabilidad del productor por clase. Validación externa con las inspecciones de campo en las comarcas agrarias CA-III y CA-VI. En las dos últimas columnas, datos agrupados de ambas comarcas. Clases ordenadas en función del número de recintos declarados en el conjunto de ambas comarcas. Se resaltan las clases con una fiabilidad superior al 80%.

Campaña 2017						
INSPECCIONES	Comarca Agraria III		Comarca Agraria VI		CA-III y CA-VI	
CULTIVO	Nº recintos inspeccionados	Fiabilidad productor 1º y 2º cultivo predicho	Nº recintos inspeccionados	Fiabilidad productor 1º y 2º cultivo predicho	Fiabilidad productor 1º y 2º cultivo predicho	Superficie media (ha)
Cebada	296	97,6	1278	97,0	97,1	1,70
Pastos	82	78,0	815	86,1	85,6	0,87
Trigo	293	98,3	520	90,4	93,2	1,44
Barbecho	35	94,3	513	89,3	89,6	1,56
Maiz	41	95,1	215	93,0	93,4	1,64
Viña	8	87,5	221	93,7	93,4	1,78
Avena	103	77,7	55	21,8	58,2	1,67
Frutales	7	28,6	108	75,0	72,2	0,45
Olivar	9	33,3	101	80,2	76,4	0,50
Arroz			105	99,0	99,0	1,55
Hortícola de verano			97	82,5	82,5	1,00
Alfalfa	2	50,0	91	91,2	90,3	1,44
Guisante	62	82,2	24	54,2	74,4	2,36
Habas	80	81,2			81,3	2,19
Colza	46	93,5			93,5	2,12
Girasol	25	88,8	15	46,7	72,5	3,17
Veza	27	66,6	10	40,0	45,9	1,66
Tomate			34	97,1	97,1	2,82
Mezcla cereal-legumin			31	25,8	25,8	0,52
Almendros	1	0,0	29	13,8	13,3	0,64
Espárragos	2	100,0	20	80,0	81,8	0,52
Horícola de invierno	5	20,0	16	43,8	38,1	0,98
Otros cult. herbáceos			9	33,3	33,3	3,06
Superficies forestales			7	14,3	14,3	3,89
Patata	2	100,0	1	100,0	100,0	0,70
Otras Leguminosas			1	100,0	100,0	8,11
TOTAL	1126	89,4	4316	88,4	88,6	1,39

4.3. Mapa de verificación obtenido

En la Figura 6 se muestra el mapa de verificación obtenido al comparar, a nivel de recinto, el cultivo declarado por el agricultor con el primer o segundo cultivo predicho a partir de los datos Sentinel-2. Asimismo, en la Tabla 5 se muestran los resultados numéricos derivados de estos mapas.

Como se puede observar en esta tabla, prácticamente el 90% de los recintos de las CA-III y CA-VI, que suponen aproximadamente el 95% de la superficie en ambas comarcas, se categorizaron como *verdes*, es decir, como declarados correctamente. En la CA-III, los recintos categorizados como *naranjas*, es decir, clasificados con un grado de incertidumbre alto, suponen el

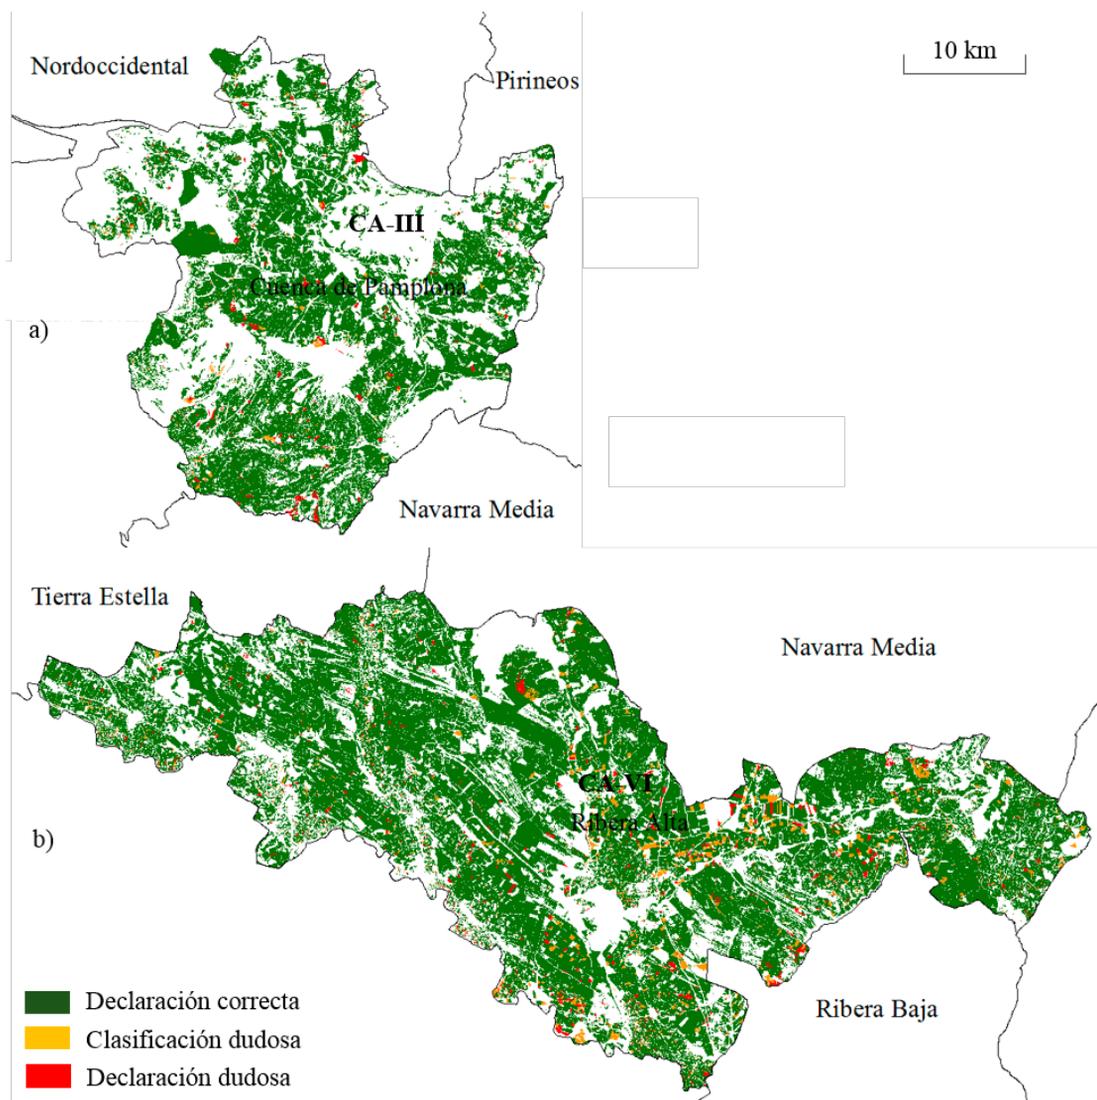


Figura 6. Mapa de verificación de declaraciones correspondiente a las comarcas CA-III (a) y CA-VI (b) en la campaña 2017.

Tabla 5. Porcentaje de recintos categorizados como verdes, naranjas o rojos del total de declarados en las comarcas CA-III y CA-VI, en la campaña 2017.

Campaña 2017		VERDES		NARANJAS		ROJOS		NO CLASIFICABLES		
DECLARACIONES										
Comarca Agraria	Recintos declarados	Superficie declarada (ha)	% recintos	% superfic	% recintos	% superfic	% recintos	% superfic	% recintos	% superfic
CA-III	25177	36375	88,91	96,68	2,39	1,16	3,55	1,96	5,18	0,20
CA-VI	56814	77329	89,78	94,21	3,93	3,42	3,03	2,18	3,32	0,20
CA-III y CA-VI	81991	113704	89,51	95,00	3,46	2,70	3,19	2,11	3,89	0,20

Tabla 6. Porcentaje de recintos categorizados como *verdes*, *naranjas* o *rojos* del total de inspeccionados en las comarcas CA-III y CA-VI, en la campaña 2017.

Campaña 2017		VERDES		NARANJAS		ROJOS		
INSPECCIONES			%	%	%	%	%	
Comarca Agraria	Recintos declarados	Superficie declarada (ha)	% recintos	% superficie	% recintos	% superficie	% recintos	% superficie
CA-III	1126	1761	84,72	91,64	7,37	4,66	7,90	5,90
CA-VI	4316	6206	81,07	86,83	13,62	9,41	5,31	3,25
CA-III y CA-VI	5442	7967	81,83	87,89	12,33	8,36	5,84	3,84

2,4% de los recintos declarados y el 1,1% de la superficie declarada, mientras que en la CA-VI, con mayor diversidad de cultivos, los recintos *naranjas* suponen el 3,9% de los recintos y el 3,4% de la superficie declarada. En cuanto a los recintos categorizados como *rojos*, en los que el cultivo declarado no coincide con el clasificado y la incertidumbre es baja, estos suponen el 3,5% y el 3% de los recintos declarados en las CA-III y CA-VI, respectivamente, y poco más del 2% de la superficie total declarada en ambas comarcas.

En lo que respecta a la muestra de validación o de inspecciones (Tabla 6), los recintos *verdes* suponen un porcentaje inferior que en el conjunto del archivo de declaraciones (Tabla 5) y los recintos *naranjas* y *rojos* un porcentaje superior. Estos *a priori* peores resultados se deben a que la selección de la muestra de recintos a inspeccionar del total de declaraciones se realiza de forma dirigida, orientada a detectar casos potencialmente conflictivos. Esto implica que la distribución de probabilidad de cultivos en el conjunto de los recintos declarados y de los recintos inspeccionados no sea igual (Tablas 1 y 2), como tampoco lo es la distribución geográfica de los recintos (Figura 2). Estos aspectos implican que el testaje y validación de los resultados obtenidos utilizando la información de las inspecciones produzca unos indicadores de evaluación algo más desfavorables de lo que cabría esperar de haberse realizado un muestreo estadístico que persiguiera la representatividad del archivo de declaraciones (Olofsson et al., 2014).

4.4. Análisis de fiabilidad del mapa de verificación

Comparar el cultivo declarado por el agricultor con el cultivo observado en campo en los recintos

inspeccionados, permite obtener una referencia real de los recintos correctamente e incorrectamente declarados con la que comparar el mapa de verificaciones generado (Figura 6). En la Tabla 7 se muestran los resultados de esta comparativa. Como ya se ha comentado anteriormente, el 81,3% de los recintos inspeccionados en el conjunto de las CA-III y CA-VI se incluyeron en la categoría *verde*, es decir, como correctamente declarados. En estos recintos, el nivel de acuerdo entre el primer o segundo cultivo predicho por el clasificador y el cultivo observado *in situ* es del 98,9%, es decir, que la fiabilidad global del clasificador es casi del 99%. Tal y como se indica en la Tabla 7, el número de *falsos verdes* (recintos incorrectamente declarados que han sido categorizados como correctamente declarados), es de 5 y de 35 en las CA-III y CA-VI, respectivamente, lo que implica una tasa de *falsos verdes* del 0,52% y del 1% en ambas comarcas, muy por debajo del 5% marcado como objetivo por la Comisión Europea (Devos et al., 2018a; 2018b). En lo que respecta a los recintos categorizados como *rojos*, que suponen tan sólo el 7,9% y el 5,31% de los recintos inspeccionados en la CA-III y CA-VI, respectivamente, se aprecia que el porcentaje de recintos correctamente clasificados es muy bajo, del 10,1% y del 25,7% en la CA-III y CA-VI, respectivamente. Esta incorrecta clasificación, hace que la tasa de *falsos rojos* (recintos con declaración correcta incluidos en la categoría de declaración dudosa) sea del 83,1% y del 71,6% en la CA-III y CA-VI, respectivamente, muy por encima del 5% marcado como objetivo por la Comisión Europea (Devos et al., 2018a; 2018b). Estos resultados ponen de manifiesto que los recintos categorizados como *rojos* según la metodología aplicada en el contexto de este trabajo, requieren del análisis y juicio

Tabla 7. Fiabilidad del mapa de verificación: recintos categorizados como *verdes*, *naranjas* y *rojos*, recintos correcta e incorrectamente clasificados en cada categoría, recintos con declaración incorrecta incluidos en cada categoría y *tasa de falsos verdes y falsos rojos*.

Campaña 2017 INSPECCIONES							
Comarca Agraria	Recintos inspeccionados	Nº Recintos	% Recintos	Cultivo predicho = inspeccionado	Cultivo predicho ≠ inspeccionado	Declaraciones incorrectas incluidas	% FALSOS VERDES o ROJOS
VERDES							
CA-III	1126	954	84,72	952	2	5	0,52
CA-VI	4316	3499	81,07	3452	47	35	1,00
CA-III y CA-VI	5442	4453	81,83	4404	49	40	0,90
NARANJAS							
CA-III	1126	83	7,37	45	38	4	
CA-VI	4316	588	13,62	302	286	117	
CA-III y CA-VI	5442	671	12,33	347	324	121	
ROJOS							
CA-III	1126	89	7,90	9	80	15	83,15
CA-VI	4316	229	5,31	59	170	65	71,62
CA-III y CA-VI	5442	318	5,84	68	250	80	74,84

posterior de un experto e incluso, de la solicitud de información adicional al agricultor. Por ello, se propone utilizar el nombre de *declaración dudosa* para denominar a los recintos incluidos en esta categoría, que tras las consiguientes aclaraciones podrán en su caso ser considerados como *declarados incorrectamente*. No obstante, consideramos importante señalar que aunque el porcentaje de falsos rojos es elevado en términos relativos, en términos absolutos implica a un número muy reducido de parcelas si se compara con el total de parcelas inspeccionadas.

En cuanto a los recintos categorizados como *naranjas*, estos suponen el 7,4% y el 13,6% de los recintos inspeccionados en la CA-III y CA-VI, respectivamente. Esta categoría incluye todos los recintos clasificados con un grado de incertidumbre alto. De hecho, tal y como se muestra en la Tabla 7, el número de recintos correcta e incorrectamente clasificados en esta categoría es muy similar tanto en la CA-III como en la CA-VI. Esto respalda la consideración de *clasificados dudosos* de estos recintos, que requerirán, al igual que los recintos categorizados como *rojos*, del análisis y juicio posterior de un experto para decidir si finalmente se asignan a la categoría *verde* o *roja*.

De los datos de la Tabla 7 se puede concluir que existe una relación directa entre el número de recintos correctamente clasificados y la tasa de *falsos verdes* o *falsos rojos* del mapa de verificación. De hecho, tal y como se resume en la Tabla 8, la fiabilidad global de la clasificación es próxima al 99% en el conjunto de recintos categorizados como *verdes*, reduciéndose este valor al 54,2% y 51% en los recintos categorizados como *naranjas* en las CA-III y CA-VI, respectivamente, y al 10,1% y 25,7% en los recintos categorizados como *rojos*.

Todo ello refleja que las reglas para determinar el grado de incertidumbre en la clasificación y de los criterios para la categorización de cada recinto en función del grado de acuerdo entre declaración y predicción Sentinel-2, son acertados y sobre todo, permiten identificar los recintos correctamente declarados con una tasa de *falsos verdes* inferior al 1%. No obstante, es importante destacar que aunque la tasa de *falsos rojos* sea alta, la mayor parte de los recintos con declaraciones incorrectas se han incluido en las categorías *naranja* y *roja* del mapa de verificación (Tabla 9). De hecho, del total de 241 declaraciones incorrectas detectadas en el conjunto de las CA-III y CA-VI, el 83,4% se concentran en los recintos categorizados como

Tabla 8. Fiabilidad global de la clasificación en los recintos categorizados como *verdes*, *naranjas* y *rojos* en el mapa de verificación. Validación externa con las inspecciones de campo en las comarcas CA-III y CA-VI.

Campaña 2017				
INSPECCIONES		VERDES	NARANJAS	ROJOS
Comarca Agraria	Parcelas inspeccionadas	Fiabilidad clasificador 1º y 2º cultivo predicho	Fiabilidad clasificador 1º y 2º cultivo predicho	Fiabilidad clasificador 1º y 2º cultivo predicho
CA-III	1126	99,79	54,22	10,11
CA-VI	4316	98,66	51,36	25,76
CA-III y CA-VI	5442	98,89	51,95	22,53

Tabla 9. Porcentaje de declaraciones incorrectas entre los recintos inspeccionados y categorizados como *verdes*, *naranjas* y *rojos* en el mapa de verificación.

Campaña 2017					
INSPECCIONES					
Comarca Agraria	Recintos inspeccionados	Recintos con declaración incorrecta	% Declaraciones incorrectas en VERDES	% Declaraciones incorrectas en NARANJAS	% Declaraciones incorrectas en ROJOS
CA-III	1126	24	20,8	16,7	62,5
CA-VI	4316	217	10,8	57,4	31,9
CA-III y CA-VI	5442	241	16,6	50,2	33,2

naranjas o *rojos* en el mapa de verificación. Es precisamente en estos recintos en los que los servicios de inspección y organismos pagadores pueden centrar sus esfuerzos, ya que incluyen la gran mayoría de declaraciones incorrectas.

Si estos datos se extrapolan al conjunto de declaraciones correspondientes a las CA-III y CA-VI (Tabla 5), el análisis y juicio posterior de los técnicos de inspección sería únicamente necesario en

el 6,7% de los recintos declarados, categorizados como *naranjas* o *rojos* (Tabla 5), es decir *dudosos*, donde se concentrarían más del 80% de las declaraciones incorrectas.

Por último, con el fin de analizar si el tamaño y la forma de los recintos declarados puede condicionar la fiabilidad en su verificación, se ha calculado la superficie y la relación perímetro/superficie de los

Tabla 10. Datos medios de tamaño y forma de los recintos categorizados como *verdes*, *naranjas* y *rojos* del total de declarados e inspeccionados en la campaña 2017.

Campaña 2017									
DECLARACIONES		VERDES		NARANJAS		ROJOS		NO CLASIFICABLES	
Comarca Agraria	Recintos declarados	Superf media (ha)	media perímetro/área						
CA-III	25177	1,57	0,11	0,70	0,18	0,80	0,22	0,06	0,32
CA-VI	56814	1,43	0,10	1,18	0,12	0,98	0,13	0,08	0,33
CA-III y CA-VI	81991	1,46	0,10	1,12	0,13	0,93	0,15	0,07	0,32

Campaña 2017
INSPECCIONES

Comarca Agraria	Recintos declarados	Superf media (ha)	media perímetro/área	Superf media (ha)	media perímetro/área	Superf media (ha)	media perímetro/área
CA-III	1126	1,71	0,07	0,53	0,20	0,97	0,19
CA-VI	4316	1,55	0,08	1,05	0,17	0,89	0,18
CA-III y CA-VI	5442	1,58	0,08	0,99	0,17	0,91	0,18

recintos categorizados como *verdes*, *naranjas* y *rojos*.

Tal y como se observa en la tabla 10, los recintos categorizados como *verdes* tienen una superficie media de aproximadamente 1,5 ha y una relación perímetro/superficie de aproximadamente 0,10, lo que indica que son recintos relativamente grandes y compactos. Sin embargo, los recintos categorizados como *naranjas* y *rojos* son más pequeños y tienen una relación perímetro/superficie mayor, lo que indica que son más alargados. Por último, se observa cómo los recintos *no clasificables* (sin dato Sentinel-2) tienen una superficie media de 0,07 ha y un ratio perímetro/área de 0,327, es decir, son muy pequeños y alargados (Figura 7). Si se analizan conjuntamente estos datos con los de las Tablas 7 y 8 se observa que hay una relación clara entre la geometría de los recintos y la fiabilidad en la predicción del cultivo por el clasificador, y por lo tanto, en la correcta verificación de la declaración presentada por el agricultor. Esta fiabilidad es muy alta en los recintos grandes y compactos, en su mayoría categorizados como *verdes*, entre los que apenas hay recintos mal clasificados. Por el contrario, el grado de acierto baja en los recintos categorizados como *naranjas* y *rojos*, que tienen menor superficie y una forma más alargada, lo que dificulta su correcta clasificación a partir de datos de imágenes Sentinel-2 y por lo tanto, su correcta verificación.

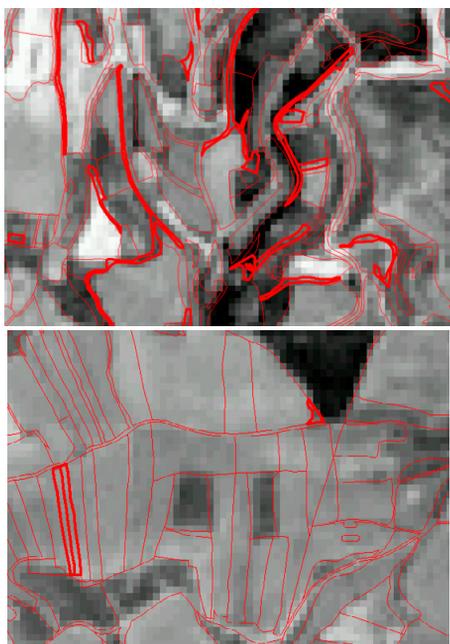


Figura 7. Ejemplo de recintos no clasificables superpuestos a la B4 de una imagen Sentinel-2, con una resolución espacial de 10 m.

La dificultad de clasificar, y por lo tanto verificar, correctamente parcelas pequeñas y alargadas ha sido puesta de manifiesto en estudios similares (Defourny et al., 2019). La solución a esta problemática no resulta sencilla. Por un lado se podría plantear la clasificación de estos recintos con imágenes de muy alta resolución espacial, pero esto incrementaría el coste económico y computacional de la verificación. Otra opción más sencilla y operativa podría ser la integración de estos recintos en recintos vecinos declarados con el mismo cultivo para conformar polígonos mayores y más compactos que se clasificarían mejor. O incluso se podría plantear excluir este tipo de recintos del proceso de verificación, ya que la superficie declarada que suponen es muy baja, por lo que el montante económico del fraude (en caso de haberlo) sería prácticamente insignificante.

5. Conclusiones y líneas futuras

La estrategia para la verificación de declaraciones PAC propuesta en este trabajo se basa en la identificación del cultivo más probable en cada recinto o parcela, a través de la clasificación supervisada de los mismos. Por lo tanto, la fiabilidad de la verificación depende directamente de la fiabilidad de la clasificación, que a su vez depende de la disponibilidad de imágenes Sentinel-2 libres de nubes, de la diversidad de clases o cultivos considerados, de la cantidad y calidad de la muestra de entrenamiento disponible para cada clase así como del tamaño y forma de los recintos a clasificar. Aunque la disponibilidad de imágenes Sentinel-2 libres de nubes en Navarra en la campaña de estudio fue reducida y apenas se dispuso de datos en el periodo comprendido entre mediados de abril hasta mediados de junio, esto no afectó negativamente a la identificación de cultivos, especialmente cereales, que se clasificaron con fiabilidades más que satisfactorias, incluso en la Comarca Agraria VI, donde la diversidad de cultivos implicó una leyenda de casi treinta clases.

El procedimiento propuesto para generar una muestra de entrenamiento a partir de las declaraciones PAC, las reglas definidas para determinar el grado de incertidumbre en la clasificación y

los criterios propuestos para categorizar el nivel de acuerdo entre la declaración del agricultor y la predicción derivada de la monitorización Sentinel-2, han permitido identificar los recintos con declaraciones correctas, categorizados como *verdes*, con un grado de error (tasa de *falsos verdes*) muy por debajo del 5% fijado como objetivo por la Comisión Europea. Por el contrario, la identificación de declaraciones incorrectas no ha arrojado tasas de error similares, lo que implica que los recintos categorizados como *rojos*, con *declaración dudosa*, requerirán del análisis y juicio posterior de técnicos de inspección, al igual que los recintos categorizados como *naranjas*, o con *clasificación dudosa*. Señalar no obstante que los recintos categorizados como *naranjas* y *rojos* suponen un porcentaje reducido de los declarados y se da la circunstancia de que concentran la gran mayoría de las declaraciones incorrectas, lo que acota sustancialmente la labor de seguimiento e inspección.

El análisis conjunto de la fiabilidad de la clasificación y el tamaño y forma de los recintos en función de su categorización en el mapa de verificación, ha permitido determinar que existe una clara relación entre la geometría de los recintos y la fiabilidad en la predicción del cultivo por el clasificador, y por lo tanto, en la certidumbre de la verificación. Esta fiabilidad es muy alta en los recintos categorizados como *verdes*, más grandes y compactos, y mucho menor en los recintos categorizados como *naranjas* y *rojos*, con menor superficie y forma más alargada. Se considera que la unión de recintos de menor tamaño a recintos adyacentes que tengan el mismo cultivo declarado puede incrementar la fiabilidad del clasificador. Asimismo, la incorporación de datos derivados de las imágenes Sentinel-1, así como de variables predictivas que permitan considerar la variación temporal de los datos Sentinel-1 o Sentinel-2, podría permitir incrementar la fiabilidad de la clasificación y con ello, de los resultados derivados de la estrategia de verificación presentada en este trabajo.

Agradecimientos

Este trabajo se ha financiado con el proyecto PyrenEOS EFA 048/15, cofinanciado al 65% por el Fondo Europeo de Desarrollo Regional (FEDER) a través del programa Interreg V-A

España-Francia-Andorra (POCTEFA 2014-2020). Los autores agradecen al Servicio del Organismo Pagador del Departamento de Desarrollo Rural y Medio Ambiente del Gobierno de Navarra la cesión de los ficheros vectoriales de declaraciones e inspecciones PAC utilizadas en el contexto de este trabajo.

Referencias

- Amitrano, D., Guida, R., Ruello, G. 2019. Multitemporal SAR RGB Processing for Sentinel-1 GRD Products: Methodology and Applications. *IEEE Journal of Selected Topics in Applied Earth Observation and Remote Sensing*, 12(5), 1497-1507. <https://doi.org/10.1109/JSTARS.2019.2904035>
- Belgiu, M., Dragut, L. 2016. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24-31. <https://doi.org/10.1016/j.jrse.2017.10.005>
- Belgiu, M., Csillik, O. 2018. Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. *Remote Sensing of Environment*, 204, 509-533. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Boryan, C., Yang, Z., Mueller R., Craig, M. 2011. Monitoring US agriculture: the US Department of Agriculture, National Agricultural Statistics Service, Cropland Data Layer Program. *Geocarto International*, 26(5), 341-358. <https://doi.org/10.1080/10106049.2011.562309>
- Breiman, L. 2001. Random Forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Chakhar, A., Ortega-Terol, D., Hernández-López, D., Ballesteros, R., Ortega, J.F., Moreno, M.A. 2020. Assessing the Accuracy of Multiple Classification Algorithms for Crop Classification Using Landsat-8 and Sentinel-2 Data. *Remote Sensing*, 12, 1735. <https://doi.org/10.3390/rs12111735>
- Chuvieco, E., Huete, A. 2010. *Fundamentals of satellite remote sensing*. Boca Raton: CRC Press. <https://doi.org/10.1201/b18954>

- Defourny, P., Bontemps, S., Bellemans, N., Cara, C., Dedieu, G., Guzzonato, E., Hagolle, O., Inglada, J., Nicola, L., Rabaute, T., Savinaud, M., Udroui, C., Valero, S., Bégué, A., Dejoux, J.F., El Harti, A., Ezzahar, J., Kussul, N., Labbassi, K., Lebourgeois, V., Miao, Z., Newby, T., Nyamugama, A., Salh, N., Shelestov, A., Simonneaux, V., Traore, P.S., Traore, S.S., Koetz, B. 2019. Near real-time agriculture monitoring at national scale at parcel resolution: Performance assessment of the Sen2-Agri automated system in various cropping systems around the world. *Remote Sensing of Environment*, 221, 551-568. <https://doi.org/10.1016/j.rse.2018.11.007>
- Devos, W., Kay, S. 2011. *LPIS quality inspection: EU requirements and methodology*. JRC Technical notes. Ispra: Publications Office of the European Union.
- Devos, W., Lemoine, G., Milenov, P., Fasbender, D. 2018a. *Technical guidance on the decision to go for substitution of OTSC by monitoring*. EUR 29370 EN. Ispra: Publications Office of the European Union.
- Devos W., Lemoine G., Milenov P., Fasbender D., Loudjani P., Wirnhardt C., Sima A., Griffiths P. 2018b. *Second discussion document on the introduction of monitoring to substitute OTSC: rules for processing applications in 2018-2019*. EUR 29369 EN. Ispra: Publications Office of the European Union.
- European Court of Auditors. 2016. *The Land Parcel Identification System: A useful tool to determine the eligibility of agricultural land – but its management could be further improved*. Special report No 25. Luxembourg: European Court of Auditors.
- Foley, J.A., DeFries, R., Asner, G.P., Barford, C., Bonan, G., Carpenter, S.R., Chapin, F.S., Coe, M.T., Daily, G.C., Gibbs, H.K., Helkowski, J.H., Holloway, T., Howard, E.A., Kucharik, C.J., Monfreda, C., Patz, J.A., Prentice, I.C., Ramankutty, N., Snyder, P.K. 2005. Global consequences of land use. *Science*, 309, 570. <https://doi.org/10.1126/science.1111772>
- Gascon, F., Bouzinac, C., Thépaut, O., Jung, M., Francesconi, B., Louis, J., Lonjou, V., Lafrance, B., Massera, S., Gaudel-Vacaresse, A., Languille, F., Alhammoud, B., Viallefont, F., Pflug, B., Bieniarz, J., Clerc, S., Pessiot, L., Trémas, T., Cadau, E., De Bonis, R., Isola, C., Martimort, P., Fernandez, V. 2018. Copernicus Sentinel-2A Calibration and Products Validation Status. *Remote Sensing*, 9, 584. <https://doi.org/10.3390/rs9060584>
- Hogan, P. 2018. CAP post 2020: the evolution of the policy. *NEW MEDIT*, 17(2), 1-2.
- Jin, K.H., McCann, M.T., Froustey, E., Unser, M. 2017. Deep Convolutional Neural Network for Inverse Problems in Imaging. *IEEE Transactions on Image Processing*, 26(9), 4509-4522. <https://doi.org/10.1109/TIP.2017.2713099>
- Koetz, B., Defourny, P., Bontemps, S., Bajec, K., Cara, C., de Vendictis, L., Kucera, L., Malcorps, P., Milcinski, G., Nicola, L., Rossi, L., Sciarretta, C., Slacikova, J., Tutunaru, F., Udroui, C., Zavagli, M. 2019. SEN4CAP Sentinels for CAP monitoring approach. En: *Proceedings of the 2019 JRC IACS Workshop*, Valladolid, Spain, 10-11 April 2019
- Koschke, L., Fürst, C., Frank, S., Makeschin, F. 2012. A multi-criteria approach for an integrated land-cover-based assessment of ecosystem services provision to support landscape planning. *Ecological Indicators*, 21, 54-66. <https://doi.org/10.1016/j.ecolind.2011.12.010>
- Louis, J., Pflug, B., Main-Knorn, M., Debaecker, V., Mueller-Wilm, U., Iannone, R.Q., Cadau, E.G., Boccia, V., Gascon, F. 2019. Sentinel-2 Global Surface Reflectance Level-2A Product generated with SEN2COR. En: *Proceedings of IEEE International Geoscience and Remote Sensing Symposium*. Yokohama, Japon, 28 Julio-02 Agosto. pp 8522-8525. <https://doi.org/10.1109/IGARSS.2019.8898540>
- Maggiori, E., Tarabalka, Y., Charpiat, G., Alliez, P. 2017. Convolutional Neural Networks for Large-Scale Remote-Sensing Image Classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(2), 645-657. <https://doi.org/10.1109/TGRS.2016.2612821>
- Maxwell, A.E., Warner, T.A., Fang, F. 2018. Implementation of machine-learning classification in remote sensing: an applied review. *International Journal of Remote Sensing*, 39(9), 2784-2817. <https://doi.org/10.1080/01431161.2018.1433343>
- Mellor, A., Boukir, S., Haywood, A., Jones, S. 2015. Exploring issues of training data imbalance and mislabelling on random forest performance for large area land cover classification using the ensemble margin. *ISPRS Journal of Photogrammetry and Remote Sensing*, 105, 155-168. <https://doi.org/10.1016/j.isprsjprs.2015.03.014>
- Olofsson, P., Foody, G.M., Herold, M., Stehman, S.V., Woodcock, C.E., Wulder, M.A. 2014. Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment*, 148, 42-57. <https://doi.org/10.1016/j.rse.2014.02.015>

- Orynbaikyzy, A., Gessner, U., Conrad, C. 2019. Crop type classification using a combination of optical and radar remote sensing data: a review. *International Journal of Remote Sensing*, 40(17), 6553-6595. <https://doi.org/10.1080/01431161.2019.1569791>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., Duchesnay, E. 2011. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12(85), 2825–2830.
- Petitjean, F., Inglada, J., Gancarski, P. 2012. Satellite Image Time Series Analysis Under Time Warping. *IEEE Transactions on Geoscience and Remote Sensing*, 50(8), 3081-3095. <https://doi.org/10.1109/TGRS.2011.2179050>
- Quinlan, J.R. 1996. Bagging, boosting, and C4.5. En: *Proceedings AAAI-96 fourteenth National Conference on Artificial Intelligence*. Portland, OR.
- Rizov, M., Pokrivcak, J., Ciaian, P. 2013. CAP Subsidies and Productivity of the EU Farms. *Journal of Agricultural Economics*, 64(3), 537-557. <https://doi.org/10.1111/1477-9552.12030>
- Shelestov, A., Lavreniuk, M., Kussul, N., Novikov, A., Skakun, S. 2017. Exploring Google Earth Engine Platform for Big Data Processing: Classification of Multi-Temporal Satellite Imagery for Crop Mapping. *Frontiers in Earth Science*, 5, 1-10. <https://doi.org/10.3389/feart.2017.00017>
- Sitokonstantinou, V., Papoutsis, I., Kontoes, C., Arnal, A.L., Andrés, A.P.A., Zurbano, J.A.G. 2018. Scalable parcel-based crop identification scheme using Sentinel-2 data time-series for the monitoring of the common agricultural policy. *Remote Sensing*, 10, 911. <https://doi.org/10.3390/rs10060911>
- Van Tricht, K., Gobin, A., Gilliams, S., Piccard, I. 2018. Synergistic use of radar Sentinel-1 and optical Sentinel-2 imagery for crop mapping: A case study for Belgium. *Remote Sensing*, 10, 1642. <https://doi.org/10.3390/rs10101642>
- Veloso, A., Mermoz, S., Bouvet, A., Le Toan, T., Planells, M., Dejoux, J.F., Ceschia, E. 2017. Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. *Remote Sensing of Environment*, 199, 415-426. <https://doi.org/10.1016/j.rse.2017.07.015>