



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



Escola Tècnica Superior
d'Enginyeria Agronòmica i del Medi Natural

UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escola Tècnica Superior d'Enginyeria Agronòmica i
del Medi Natural

Estudi Tècnic per a la Classificació de Cobertures del Sòl
Forestal a partir d'Imatges Sentinel-2 mitjançant
Fotointerpretació i Algoritmes d'Aprenentatge Automàtic

Treball Fi de Grau

Grau en Enginyeria Forestal i del medi natural

AUTOR/A: Casesnoves Andrés, Fernando

Tutor/a: Delgado Artes, Rafael

Cotutor/a extern: Van Den Berg Sesma, Helena Carmen

CURS ACADÈMIC: 2024/2025

RESUM

En les darreres dècades, l'abandó agrari i la regeneració natural han afavorit l'expansió dels boscos en gran part del territori mediterrani. Aquest procés incrementa la càrrega de combustible i disminueix les discontinuïtats del paisatge —mosaics agrícoles, clarianes i zones gestionades— que actuaven com a tallafocs naturals. Com a conseqüència, els incendis presenten major continuïtat i intensitat, amb més probabilitat d'evolucionar cap a grans incendis forestals. Davant aquest escenari, es fa imprescindible una gestió forestal activa i adaptativa que recupere el mosaic territorial i reduïska la continuïtat del combustible.

La motivació principal del present treball és generar informació actualitzada que done suport a la planificació territorial i a la gestió forestal en un context de canvis d'ús de sòl i risc d'incendis forestals, mitjançant ferramentes de lliure accés. Aquest treball desenvolupa i avalua una metodologia per a la classificació d'usos i cobertes del sòl a la província de Castelló, combinant imatges multiespectrals Sentinel-2, estadístiques zonals i algoritmes d'aprenentatge automàtic entrenats amb dades obtingudes mitjançant fotointerpretació.

Metodològicament, (1) es construeix una base de dades a partir de parcel·les fotointerpretades, (2) es calculen estadístiques zonals de les bandes de Sentinel-2 i variables auxiliars (MDT i pendent), (3) i es comparen diversos models algorítmics en WEKA; (4) el algoritme seleccionat s'implementa en Python per a l'aplicació operativa, (5) i es prova en un escenari pilot (Benassal) integrant els resultats en QGIS per al seu anàlisi cartogràfic.

Paraules clau: Sentinel-2; teledetecció; aprenentatge automàtic; usos del sòl; WEKA; fotointerpretació; estadístiques zonals; QGIS.

ABSTRACT

In recent decades, agricultural abandonment and natural regeneration have fostered forest expansion across much of the Mediterranean. This process increases fuel loads and reduces landscape discontinuities—agricultural mosaics, clearings, and managed areas—that acted as natural firebreaks. Consequently, wildfires exhibit greater continuity and intensity, with a higher likelihood of evolving into large forest fires. In this scenario, active and adaptive forest management is essential to restore the landscape mosaic and reduce fuel continuity.

The main motivation of this work is to generate up-to-date information to support territorial planning and forest management in a context of land-use change and wildfire risk, using open-access tools. This study develops and evaluates a methodology for the classification of land use and land cover in the province of Castelló, combining Sentinel-2 multispectral imagery, zonal statistics, and machine-learning algorithms trained with data obtained through photointerpretation.

Methodologically, (1) a database is built from photointerpreted parcels, (2) zonal statistics are computed for Sentinel-2 bands and auxiliary variables (DEM and slope), (3) several algorithmic models are compared in WEKA; (4) the selected algorithm is implemented in Python for operational application, (5) and it is tested in a pilot area (Benassal), integrating the results into QGIS for cartographic analysis.

Keywords: Sentinel-2; remote sensing; machine learning; land use; WEKA; photointerpretation; zonal statistics; QGIS.

RESUMEN

En las últimas décadas, el abandono agrario y la regeneración natural han favorecido la expansión de los bosques en gran parte del territorio mediterráneo. Este proceso incrementa la carga de combustible y disminuye las discontinuidades del paisaje —mosaicos agrícolas y zonas gestionadas— que actuaban como cortafuegos naturales. Como consecuencia, los incendios presentan mayor continuidad e intensidad, con más probabilidad de evolucionar hacia grandes incendios forestales. Ante este escenario, se hace imprescindible una gestión forestal activa y adaptativa que recupere el mosaico territorial y reduzca la continuidad del combustible.

La motivación principal del presente trabajo es generar información actualizada que apoye en la planificación territorial y a la gestión forestal en un contexto de cambios de uso de suelo y riesgo de incendios forestales, mediante herramientas de libre acceso. Este trabajo desarrolla y evalúa una metodología para la clasificación de usos y cubiertas del suelo en la provincia de Castelló, combinando imágenes multiespectrales Sentinel-2, estadísticas zonales y algoritmos de aprendizaje automático entrenados con datos obtenidos mediante fotointerpretación.

Metodológicamente, (1) se construye una base de datos a partir de parcelas fotointerpretadas, (2) se calculan estadísticas zonales de las bandas de Sentinel-2 y variables auxiliares (MDT y pendiente), (3) y se comparan varios modelos algorítmicos en WEKA; (4) el algoritmo seleccionado se implementa en Python para la aplicación operativa, (5) y se prueba en un escenario piloto (Benassal) integrando los resultados en QGIS para su análisis cartográfico.

Palabras clave: Sentinel-2; teledetección; aprendizaje automático; usos del suelo; WEKA; fotointerpretación; estadísticas zonales; QGIS.

RELACIÓ DEL TREBALL AMB ELS OBJECTIUS DE DESENVOLUPAMENT SOSTENIBLE DE L'AGENDA 2030

La cartografia d'usos del sòl amb Sentinel-2 i Machine Learning en programari lliure aporta base empírica per a la conservació i la gestió adaptativa dels ecosistemes, identificant acumulacions de biomassa i donant suport a la prevenció d'incendis (ODS 15), alhora que facilita el monitoratge continu i l'avaluació de vulnerabilitats davant incendis, onades de calor i episodis torrencials (ODS 13). La informació derivada reforça la planificació urbanística i territorial en la interfície urbà-forestal, millorant la resiliència local (ODS 11). Metodològicament, el treball impulsa la innovació replicable (ODS 9) i consolida aliances i ecosistemes de dades obertes (ODS 17), afavorint la col·laboració entre administracions, universitat i gestors del territori.

	Alto	Medio	Bajo	No procede
ODS 1. Fin de la pobreza				x
ODS 2. Hambre cero				x
ODS 3. Salud y bienestar				x
ODS 4. Educación de calidad				x
ODS 5. Igualdad de género				x
ODS 6. Agua limpia y saneamiento				x
ODS 7. Energía asequible y no contaminante				x
ODS 8. Trabajo decente y crecimiento económico				x
ODS 9. Industria, innovación e infraestructuras	x			
ODS 10. Reducción de las desigualdades				x
ODS 11. Ciudades y comunidades sostenibles	x			
ODS 12. Producción y consumo responsables				x
ODS 13. Acción por el clima	x			
ODS 14. Vida submarina				x
ODS 15. Vida de ecosistemas terrestres	x			
ODS 16. Paz, justicia e instituciones sólidas				x
ODS 17. Alianzas para lograr objetivos.	x			

ÍNDEX

INTRODUCCIÓ.....	1
Antecedents.....	2
Estat de l'art	3
OBJECTIUS	4
MATERIALS I MÈTODES	5
Àrea d'estudi	5
Relleu.....	6
Litologia i sòls	6
Marc climàtic	7
Hidrologia	8
Marc forestal.....	9
Metodologia de fotointerpretació	10
Selecció i preparació de materials	10
Definició de categories d'anàlisi	11
Desenvolupament de la fotointerpretació	12
Dades generades amb fotointerpretació	14
Metodologia d'algoritmes aprenentatge automàtic.....	16
Selecció i preparació de materials	16
Càlcul d'estadístiques zonals i base de dades d'entrenament	18
Anàlisi amb WEKA	20
Aplicació del model.....	20
RESULTATS I DISCUSSIÓ	22
Precisió d'algoritmes d'aprenentatge automàtic	22
MultilayerPerceptron	25
Aplicació del model.....	25
CONCLUSIONS.....	27
BIBLIOGRAFIA.....	31
ANNEXES	33

Annex 1. Codi d'extracció d'estadístiques zonals	33
Annex 2. Codi model d'aprenentatge	35
Annex 3. Punts Benassal fotointerpretats.....	37
Annex 4. Dades de referència fotointerpretades	40
Annex 5. Estadístiques zonals.....	41
Annex 6. Validació algoritme	45

ÍNDEX DE TAULES

Taula 1. Cobertures i usos del sòl a la província de Castelló (2024), representant jeràrquicament el nivell I que fa referència a una classificació més general i el nivell II que fa classificació més específica de les cobertures i usos. Font: elaboració pròpia.	11
Taula 2. Resultats entrenament fotointèrpret. Font: elaboració pròpia.....	14
Taula 3. Resultats entrenament algoritme. Font: elaboració pròpia.	15
Taula 4. Escenes satel·litals. Font: elaboració pròpia.	16
Taula 5. Estadístiques zonales, parcel·la 147. Font: elaboració pròpia.	19
Taula 6. Precisió algoritmes WEKA. Font: elaboració pròpia.	22
Taula 7. Estadística Kappa dels algoritmes amb major precisió WEKA. Font: elaboració pròpia.....	23
Taula 8. Mètriques de classificació per model i classe WEKA. Font: elaboració pròpia.	24
Taula 9. Mètriques de classificació per model i classe Python. Font: elaboració pròpia.	25
Taula 10. Precisió algoritme. Font: elaboració pròpia.	26

ÍNDEX DE IL·LUSTRACIONS

Il·lustració 1. Comarques i municipis de la província de Castelló. Font: elaboració pròpia.....	5
Il·lustració 2. Litologia de la província de Castelló. Font: elaboració pròpia.	7
Il·lustració 3. Parcel·la. Font: elaboració pròpia.....	10
Il·lustració 4. Plantilla predefinida.	13
Il·lustració 5. Parcel·les Benassal. Font: elaboració pròpia.....	14
Il·lustració 6. Parcel·les seleccionades en la província de Castelló. Font: elaboració pròpia.....	15
Il·lustració 7. Imatges satel·litals Castelló. Font: elaboració pròpia.....	17
Il·lustració 8. MDT Castelló. Font: elaboració pròpia.	17
Il·lustració 9. Pendants Castelló. Font: elaboració pròpia.	18
Il·lustració 10. Cobertures i usos Benassal segons algoritme. Font: elaboració pròpia.	21

INTRODUCCIÓ

En els últims anys, el risc de grans incendis forestals s'ha intensificat al Mediterrani. La combinació de l'abandonament agrícola i l'expansió de les masses forestals amb períodes més extrems de calor i sequera, ha incrementat la càrrega i la continuïtat del combustible. Els paisatges que abans funcionaven com a mosaic (camps, clarianes i discontinuïtats) han evolucionat cap a superfícies contínues de vegetació, fet que facilita focs més ràpids, intensos i difícils de contenir. Davant aquest escenari, la gestió forestal activa i adaptativa deixa de ser una opció per a convertir-se en una necessitat.

Una de les principals limitacions per a una gestió efectiva és la manca d'informació actualitzada i de fàcil accés sobre els usos i cobertes del sòl. Les administracions i els gestors sovint depenen de productes cartogràfics periòdics, amb escales temporals llargues, que no capten bé la dinàmica territorial (canvis d'ús del sòl, creixement de biomassa, noves interfícies urbà-forestals). Açò dificulta prioritzar actuacions de prevenció i avaluar-ne l'efecte al llarg del temps.

En aquest context, les dades obertes del programa Copernicus (sèrie Sentinel) representen una oportunitat clau. La seua política de lliure accés permet que qualsevol institució dispose d'imatges recents sense cost. Si aquestes dades es combinen amb programari lliure (QGIS, Python i WEKA) és possible dissenyar un flux de treball totalment obert i replicable, que democratitze la capacitat de generar informació geogràfica actualitzada i reduïska la dependència de productes comercials o projectes centralitzats.

Des del punt de vista de la gestió territorial i forestal, l'impacte potencial és immediat. En un territori com Castelló, amb litorals densament poblats i interiors forestals despoblats, disposar d'un mapa recent d'usos i cobertes pot revelar on la biomassa està augmentant per abandó de cultius i, per tant, on s'acumula combustible. Aquesta informació és essencial per planificar prevenció d'incendis (desbrossaments estratègics, franges perimetrals, tractaments silvícoles) i per monitorar anualment l'evolució del risc.

En definitiva, la motivació principal d'aquest Treball Final de Grau és desenvolupar una metodologia de classificació del sòl escalable i basat en recursos oberts, adaptat a la realitat territorial de Castelló, la qual pot ser directament utilitzada en la presa de decisions per a la planificació territorial i la gestió forestal. A més, demostra la viabilitat d'aprofitar els recursos que avui es tenen a l'abast per construir solucions efectives.

Antecedents

La cartografia dels usos i cobertes del sòl ha estat objecte de diversos projectes institucionals en les darreres dècades. A escala europea, el programa CORINE Land Cover (Coordination of Information on the Environment) es va iniciar el 1990 per a produir un inventari de l'ocupació del sòl del continent europeu. Actualment, CORINE ofereix una classificació paneuropea de la coberta terrestre amb 44 classes temàtiques i s'actualitza cada sis anys (l'última edició correspon a l'any 2018). Aquest producte té una resolució espacial moderada (25 ha de mínima unitat cartogràfiable, equivalent a ràster aproximadament 100 m) i ha demostrat gran utilitat en àmbits com la planificació ambiental, l'ordenació del territori, l'avaluació del canvi climàtic o la gestió d'emergències.

A nivell estatal, destaca el Sistema d'Informació d'Ocupació del Sòl d'Espanya (SIOSE), integrat en el Pla Nacional d'Observació del Territori. SIOSE va iniciar-se l'any 2005 amb l'objectiu de generar una base de dades contínua d'ocupació del sòl per a tot el país. SIOSE es caracteritza per un model de dades multicriteri: no es limita a assignar una sola classe per polígon, sinó que pot descriure cada zona mitjançant combinacions de cobertes i usos amb els seus percentatges. Avui en dia, SIOSE constitueix una referència geoespacial fonamental a Espanya, amb versions disponibles per als anys 2005, 2009 i 2014, i en evolució contínua per a subministrar informació més detallada i actual del territori. Tant CORINE com SIOSE proporcionen un marc de referència important per als estudis d'usos del sòl a escala regional; no obstant això, les seues limitacions en resolució espacial i temporal han impulsat la recerca de metodologies complementàries basades en noves dades satel·litals (IGN/CNIG, 2022).

En l'àmbit de la recerca aplicada, els darrers anys han vist nombrosos estudis de classificació d'usos del sòl basats en imatges Sentinel-2 i algorismes d'aprenentatge automàtic. Per exemple, *Borràs et al. (2017)* van comparar diversos mètodes de classificació (anàlisi discriminant lineal, arbres de decisió, Random Forest i veïns més pròxims k-NN) emprant imatges multiespectrals de Sentinel-2 en dues zones agrícoles (la comarca de l'Horta de València i una regió de Buenos Aires). En aquest estudi es va avaluar l'impacte de la resolució espectral de Sentinel-2 enfront de sensors anteriors, provant tant totes les 13 bandes de Sentinel-2 com només les 4 bandes equivalents al satèl·lit SPOT. Els resultats van indicar una millora significativa en la precisió de la classificació en usar totes les bandes de Sentinel-2, posant de manifest els avantatges d'aquesta missió europea per a discriminar usos del sòl diversos. Amb el millor algorisme es va generar un mapa detallat d'usos del sòl, proporcionant informació quantitativa sobre l'extensió de cada classe en les àrees d'estudi.

Estat de l'art

La fotointerpretació d'imatges aèries o satel·litals per part d'experts ha estat durant dècades la tècnica clàssica per a cartografiar usos del sòl. Mitjançant la interpretació visual d'ortofotografies, es poden obtenir mapes molt fiables, però aquest procés és costós en temps i recursos humans i subjecte a certa variabilitat depenent del fotointèrpret. Encara avui, la fotointerpretació segueix sent fonamental per a generar dades de referència amb què entrenar i validar els algorismes automàtics. Per exemple, en l'estudi de *Delgado-Artés et al. (2022)* sobre l'evolució de les cobertes forestals a Castelló, es van usar tècniques de fotointerpretació sobre fotografies aèries històriques per quantificar els canvis entre 1957 i 2007. No obstant això, la necessitat de disposar d'informació més freqüent i automatitzada ha impulsat el desenvolupament de mètodes de classificació assistits per ordinador, capaços de processar imatges satel·litals de forma consistent i replicable.

El llançament dels satèl·lits Sentinel-2A (2015) i 2B (2017) dins del programa europeu Copernicus ha revolucionat la monitorització del territori. La missió Sentinel-2 proporciona imatges multiespectrals d'alta resolució espacial (10 m en bandes clau com el visible i l'infraroig proper) amb un ample de banda ampli (13 canals espectrals) i amb alta resolució temporal (aproximadament 5 dies). Cal destacar que la disponibilitat de bandes de la vora roja (red-edge) en Sentinel-2 aporta informació addicional per caracteritzar l'estat de la vegetació (estrès hídric, contingut en clorofil·la, etc.), millorant la discriminació de cobertes forestals i agrícoles (*Delegido et al., 2011*).

Avui en dia, la categorització d'imatges de teledetecció s'assoleix principalment mitjançant algorismes d'aprenentatge supervisat, que s'entrenen amb mostres conegudes per aprendre a assignar una classe a cada píxel. Aquests algorismes aprofiten les característiques espectrals multibanda de Sentinel-2: cada píxel es representa pels valors de reflectància en cadascuna de les bandes, conformant un vector de característiques que el model utilitza per inferir la classe a la qual pertany.

Finalment, cal destacar la popularització de programari lliure especialitzat en geoinformació. Fa uns anys, implementar algorismes de classificació avançats requeria coneixements avançats de programació. Avui en dia, disposem de llibreries de codi obert com scikit-learn i PyTorch, i de plataformes com Google Earth Engine, que permeten processar imatges satel·litals amb facilitat. Igualment, aplicacions de codi obert com QGIS o interfícies gràfiques com Weka fan accessible l'experimentació amb diferents algorismes sense haver de programar des de zero.

OBJECTIUS

L'objectiu principal d'aquest Treball Final de Grau és desenvolupar un sistema de que classificar les cobertures i usos del sòl en ús forestal (i les seues subclassificacions o cobertures), agrícola i urbà a partir d'imatges multiespectrals Sentinel-2, mitjançant l'ús de l'anàlisi zonal i algoritmes d'aprenentatge automàtic, entrenats amb dades de referència generats amb fotointerpretació, concretament a la província de Castelló.

Per tal d'assolir aquest objectiu principal, s'estableixen una sèrie d'objectius específics, que corresponen a les diferents fases del treball en gabinet:

1. Desenvolupar un protocol d'entrenament per a la fotointerpretació d'ortofotografies, amb criteris homogenis i metodològics que assegurin la qualitat i la replicabilitat en la generació de dades.
2. Seleccionar i processar imatges de satèl·lit adients per a la classificació.
3. Calcular estadístiques zonals de bandes espectrals sobre les àrees d'entrenament, i integrar aquesta informació amb les dades de referència en una base de dades unificada que en permeta l'avaluació dels resultats.
4. Comparar diversos algoritmes mitjançant el programari lliure Weka, i analitzar els resultats per a seleccionar l'alternativa més adequada per a la classificació de les cobertures del sòl.
5. Aplicar l'algoritme de classificació en un escenari real i analitzar els resultats obtinguts per valorar la seua viabilitat operativa.

MATERIALS I MÈTODES


Àrea d'estudi

La superfície peninsular de la província de Castelló suma 6.636 km² i està formada per 135 municipis agrupats en 8 comarques administratives. Cinc d'aquestes comarques són d'interior (els Ports, l'Alt Maestrat, l'Alcalatén, l'Alt Millars i l'Alt Palància) i les altres tres litorals (el Baix Maestrat, la Plana Alta i la Plana Baixa).

La província de Castelló es caracteritza per una marcada vocació forestal i per la presència de tots els tipus bioclimàtics mediterranis litorals (*Rivas Martínez, 2007*). La seua morfologia, definida per alineacions muntanyoses paral·leles i perpendiculars a la costa, determina les condicions climàtiques a escala macro i mesoclimàtica, influint directament en la configuració dels ecosistemes forestals.

Al llarg del segle XX, especialment en la segona meitat, es va produir un intens èxode rural des de les zones d'interior cap al litoral, afavorit pel desenvolupament de sectors com l'agricultura de regadiu, la indústria, la construcció i el turisme (*Piqueras, 1995*). Aquesta dinàmica ha provocat la concentració de més del 80% de la població en la franja litoral, mentre que l'interior ha experimentat un procés de despoblament, sostingut parcialment per la millora de les infraestructures, activitats agroforestals i el turisme d'interior.

Com a resultat, s'ha consolidat una dualitat territorial amb conseqüències significatives sobre els ecosistemes forestals, els quals han evolucionat condicionats tant pels canvis socioeconòmics com per les característiques físiques del medi.



Il·lustració 1. Comarques i municipis de la província de Castelló. Font: elaboració pròpia.

Relleu

El territori es caracteritza per la superposició de tres orientacions estructurals: una primera, que és la principal configuradora del paisatge, corresponent als contraforts orientals de la Serralada Ibèrica, amb orientacions NO-ES. Una segona, la Serralada Costanera Catalana, amb orientacions NE-SO i una tercera, que constitueix l'àrea d'intersecció entre totes dues directrius, coneguda amb el nom de zona d'enllaç o d'interferència en la unió entre les províncies de Castelló, Tarragona i Terol, on les estructures adquireixen una orientació dominant O-E.


La major cota s'aconsegueix a Penyagolosa (1.813 m) i la menor en les zones deprimides existents en els aiguamolls litorals on s'arriben a trobar fins i tot cotes negatives per ser antigues albuferes encara no completament reblides. El pas entre les muntanyes interiors i la línia de costa es produeix amb un relleu, progressivament més baix en avançar cap al litoral, on apareixen formes que es coneixen com a planes. Sobre aquestes planes litorals es desenvolupa en l'actualitat la major part de l'activitat socioeconòmica de la província, és a dir l'agricultura intensiva de regadiu, la indústria i els serveis, així com l'expansió actual dels nuclis urbans.

Litologia i sòls

La província de Castelló exhibeix una certa heterogeneïtat litològica (il·lustració 2) que és resultat d'una prolongada evolució geològica des del Paleozoic fins a l'actualitat. El registre estratigràfic està dominat per materials sedimentaris, tot i que també hi afloren roques metamòrfiques i plutòniques.

Els sòls, desenvolupats sobre materials majoritàriament calcaris, constitueixen un recurs productiu essencial a la conca mediterrània pel seu paper en la producció vegetal i la seua escassa capacitat de renovació.

La complexa topografia i la variada geomorfologia afavoreixen certa diversitat dels sòls, mentre que les precipitacions intenses combinades amb fortes pendents potencien l'erosió, dificultant-ne la maduració i fins i tot la conservació d'aquests. Davant d'aquesta vulnerabilitat la cobertura forestal és clau per a la protecció dels sòls, però també les accions culturals humanes, com ara els abancalaments agrícoles construïts entre finals del segle XIX i inicis del XX, que han contribuït de manera significativa a mitigar els processos erosius en moltes zones.



Il·lustració 2. Litologia de la província de Castelló. Font: elaboració pròpia.

Litologia	
■ Arenes, gresos i lutites	■ Col·luvions
■ Argiles roges, conglomerats i gresos	■ Dipòsits d'albufera
■ Argiles versicolors, guixos i gresos	■ Dipòsits de fons de vall o rambla
■ Calcàries bioconstruïdes, calcàries, margues i gresos	■ Dipòsits de peu de mont
■ Calcàries i dolomies	■ Llims d'inundació
■ Calcàries travertíniques	■ Ventalls al·luvials antics
■ Calcàries taulejades, margues i bretxes calcàries	■ Ventalls al·luvials recents i cons de dejecció
■ Conglomerats, gresos i lutites	■ Ventalls deltaics
■ Dolomies i calcàries fosques taulejades, margues i guixos	■ Mantell d'escolament, dipòsit al·luvial-col·luvial
■ Dolomies i margues	■ Quarsites, pissarres i esquists
■ Dolomies, bretxes, carnoles i calcàries taulejades	■ Roques basàltiques alcalines
■ Gresos i pissarres	■ Roques subvolcàniques bàsiques (ofites)
■ Gresos, lutites i calcàries. Fàcies Purbeck	■ Cordó de dunes, mantell eòlic i platja
■ Gresos, lutites i calcàries. Fàcies Weald	■ Argiles de descalcificació
■ Gresos i lutites roges. Fàcies Buntsandstein	■ Terrasses
■ Ritmita calcària, calcàries oncolítics i oolítics i margues	■ Torbera
■ Masses d'aigua	■ Zones portuàries

Marc climàtic

El clima es pot qualificar com a mediterrani amb una forta tendència subtropical en les zones més baixes, ambientalment humides, i una aproximació progressiva al submediterrani a l'interior (Pérez, 1994).

El principal gradient climàtic es dona entre costa i interior, havent-hi forts contrastos en els extrems, tot i això, a major escala aquesta distribució la matisen localment factors orogràfics.

A la franja costanera, la influència termoreguladora de la mar origina hiverns temperats i estius calorosos amb un període sec ben definit; cap a l'interior, la continentalitat augmenta progressivament, fet que es reflecteix en una amplitud

tèrmica més gran i en una elevada freqüència de gelades per irradiació (fins a 100 dies anuals a Penyagolosa).

Les precipitacions, en la majoria del territori responen a l'impacte de fronts marítims de component est que, en topar amb les serralades litorals, desencadenen episodis torrencials de "gota freda" concentrats entre setembre i octubre, mentre que en les zones interiors més elevades pot haver un altre màxim primaveral d'origen atlàntic.

Els vents es caracteritzen per ser febles i variats, amb escasses calmes. A l'estiu, les onades de calor associades al vent de ponent aporten episòdicament aire molt sec, mentre que les brises marines (E-SE) refresquen la façana costanera. A la tardor, els llevants intensifiquen la pluviositat, i a l'hivern predominen vents del nord que accentuen el descens tèrmic. Els vents de major intensitat solen ser de component noroest (Mestral) en èpoques tardorenques o primaverals.

Hidrologia

La xarxa hidrològica està constituïda per conques que naixen en les serralades interiors (oest) i vessen directament a la Mediterrània, llevat del riu Bergantes, que és afluent del riu Ebre. A excepció del Millars (156 km), els cursos principals fan un recorregut curt (85 km el riu Palància, 49 el km el riu de la Sénia, 50 km la rambla Cervera, 59 km riu Cervol) o molt curt (18 km el riu Belcaire) fins a desembocar en la mar, amb cabals normalment intermitents i irregulars (excepte el riu Millars i el Palància en la seua zona mitjana), de manera que les aigües subterrànies tenen una major importància que les superficials per al proveïment de les necessitats humanes.

En general, el cabal depèn de la pluviositat, especialment tardorenca. L'únic riu amb influència nival és el Millars, que a la crescuda tardorenca se li suma una de primaveral. La dependència pluvial, la torrencialitat d'aquestes precipitacions i la naturalesa càrstica del terreny expliquen la irregularitat de la circulació fluvial, quan no la seua inexistència durant gran part de l'any. És de ressenyar la importància de les rambles, a través de les quals drenen grans superfícies de terreny, destaca la rambla de la Viuda amb 1.510 km² de conca i 90 km de longitud.

La regulació hidràulica artificial és molt important, principalment en la zona sud, en què els embassaments es van dedicar principalment a l'increment de les zones de regadiu de les planes litorals i zones annexes durant el segle XX (*Calatayud, 1993*). Aquesta regulació ha permès contindre crescudes importants i previndre grans danys, especialment en la plana litoral de La Plana Baixa.

Marc forestal

La província manté un perfil marcadament forestal: el 63,65 % de la seua superfície està catalogada com a tal, amb forts contrastos territorials que reflecteixen la dualitat interior–costa. Als espais d’interior, com l’Alt Millars i els Ports, la cobertura supera el 70 %, mentre que a les comarques litorals cau per sota del 50 % (*Delgado-Artés et al., 2022*). Administrativament, el territori s’organitza en tres demarcacions forestals que responen a criteris físics, socioeconòmics i de gestió. Tot i que el 82 % de la superfície forestal és de propietat privada, els convenis i consorcis existents amplien l’abast de la gestió pública (*Comitè Econòmic i Social, 2017*).

La diversitat altitudinal, climàtica i edàfica origina una rica successió de pisos i horitzons bioclimàtics (*Rivas-Martínez, 2007*) que, matisats per la presència de les serralades prelitorals al nord i de grans valls fluvials obertes al sud-est, configuren un gradient de pèrdua de continentalitat cap a la costa o de penetració marítima cap a l’interior (*Blanco et al., 1997*).

Respecte a la composició específica de les masses forestals, s’observa com *Pinus halepensis* domina en la major part de la terra més baixa i litoral i és progressivament substituït en els massissos muntanyencs interiors del nord del riu Millars per *P. nigra* ssp *salzmanii* (a partir dels 600 msnm), mentre que *P. sylvestris* únicament forma taques apreciables en els voltants de Penyagolosa i en La Tinença de Benifassà, en zones edàficament més descarbonatades. *P. pinea* i *P. pinaster* ssp *mesogeensis* es presenten com dues singularitats associades puntualment a les característiques edàfiques silicícoles, especialment en la serra d’Espadà.

Les frondoses estan dominades per *Quercus ilex* ssp *bellota*, especialment en les muntanyes de la zona interior septentrional, encara que resulta molt ressenyable la importància de *Q. suber*, principalment en la Serra d’Espadà. Altres frondoses, com *Q. faginea* ssp *faginea* solament formen agrupacions apreciables en les zones de mitja muntanya, per damunt de la distribució de *Q. ilex* i molt associat a *P. nigra*. També és de ressenyar l’existència de nombroses singularitats com a rodals *Q. pyrenaica* en les zones amb substrat de reacció àcida o fins i tot un rodal de *Fagus sylvatica* en les zones més humides de La Tinença de Benifassà.


Metodologia de fotointerpretació

La fotointerpretació és una tècnica que permet l'anàlisi dels canvis en l'ús i la coberta del sòl, especialment útil en estudis històrics o quan cal disposar de dades interpretades per comprendre millor la informació obtinguda de diverses fonts d'imatges, com ara fotografies aèries o dades satel·litals (Avery & Berlin, 1992). Consisteix a identificar i classificar els elements presents a les imatges mitjançant criteris tècnics, interpretatius i geoespacials. La metodologia aplicada en aquest estudi es basa en una seqüència sistemàtica que busca la coherència, la precisió i la replicabilitat dels resultats.

Selecció i preparació de materials

Per a la fotointerpretació s'ha usat un mosaic d'ortofotografies en color natural (RGB) i fals color infraroig (IRG) que cobreix el País Valencià, elaborat a 25 cm de resolució, partint del vol fotogramètric digital RGBI realitzat durant el període del 29/05/2024 al 24/08/2024. L'ortofotografia es distribueix per fulles 1:5.000, sent accessible per a la seua descàrrega en format ECW (RGB 3 bandes) i TIFF (RGBI 4 bandes). Té una profunditat de color a 8 bits per banda i el sistema de referència geodèsic és ETRS89 i projecció UTM en el fus 30. Les ortofotografies emprades procedeixen de l'arxiu fotogràfic de la Generalitat Valenciana (ICV, 2024).

La fotointerpretació s'ha realitzat sobre una pantalla mitjançant el sistema de informació geogràfica QGIS. Per a l'obtenció de la informació sobre les cobertures i usos del territori es disposa una xarxa de parcel·les de mostreig quadrades, de 100 m de costat distribuïdes sistemàticament, atès que aquest disseny de mostreig és el que aconsegueix major precisió relativa en l'estimació d'àrees en mostreig per teledetecció. El centre de simetria de cadascuna de les parcel·les coincideix amb els punts d'encreuament de la malla UTM del mapa topogràfic a escala 1.25.000 (ICV, 2001), i que per tant estan separades 1 km entre si, resultant una intensitat de mostreig de 1ha per km², equivalent al 1% de la superfície de la província.



Il·lustració 3. Parcel·la. Font: elaboració pròpia.

Definició de categories d'anàlisi

En la classificació de les cobertures forestals s'han tingut en compte altres treballs que han estudiat l'evolució de les cobertures i els usos del sòl (*Delgado-Artés et al., 2022*) així com la categorització utilitzada pels principals projectes que han emprat la teledetecció per a la valoració de les cobertures i usos del sòl, com CORINE Land Cover (*EEA, 2019*) i SIOSE (*IGN, 2020*). Aquesta base de dades geogràfiques constitueix fins ara l'esforç més complet d'informació homogènia sobre usos i ocupació del sòl per a tot l'Estat.

Cada categoria ha estat identificada mitjançant descriptors visuals (color, textura, forma, patró, context), segons els criteris clàssics de la fotointerpretació (*Avery & Berlin, 1992*).

Nivell I	Nivell II
Cobertura i usos generals	Cobertura i usos específics
Forestal; [cobertura]	Forestal Arbrat (FA); [cobertura]
	Forestal Matoll (FM); [cobertura]
	Pastures i afloraments rocosos (PArP); [cobertura]
Agrícola abandonat; [cobertura]	Agrícola abandonat (HL); [cobertura]
Agrícola; [us]	Agrícola herbaci de secà (AgHS); [us]
	Agrícola llenyós de secà (AgLS); [us]
	Agrícola herbaci de regadiu (AgHR); [us]
	Agrícola llenyós de regadiu (AgLR); [us]
Urbà; [us]	Urbà residencial (UR); [us]
	Urbà industrial (Uind); [us]
	Urbà de infraestructures (Uinf); [us]
Altres; [us]	Altres usos i cobertures (O); [us]

Taula 1. Cobertures i usos del sòl a la província de Castelló (2024), representant jeràrquicament el nivell I que fa referència a una classificació més general i el nivell II que fa classificació més específica de les cobertures i usos.

Font: elaboració pròpia.

Desenvolupament de la fotointerpretació

La fase de fotointerpretació s'ha estructurat en dues etapes diferenciades, orientades tant a l'entrenament del criteri del fotointèrpret com a la generació d'un conjunt de dades per a la validació dels models d'aprenentatge automàtic.


En una primera etapa, s'ha realitzat la fotointerpretació de la totalitat de les parcel·les corresponents al terme municipal de Benassal de les ortofotografies de l'any 2007 i de 2024 (*ICV, 2007 i 2024*), aplicant la classificació d'usos i cobertures del sòl definida prèviament segons els criteris establerts.

Per a cada parcel·la, s'han identificat i enregistrat diverses variables de cobertura, entre les quals destaquen la cobertura arbrada, la cobertura de matoll, i altres atributs complementaris rellevants per a l'anàlisi territorial. El procediment emprat ha seguit una seqüència estandarditzada. En primer lloc, es determinava el nivell I de classificació, que diferenciava si la superfície era de caràcter forestal, agrícola abandonada, agrícola o urbana. En els casos en què la coberta era forestal, urbana o agrícola, s'accedia al nivell II per a detallar amb major precisió les seues característiques específiques.

Quan la classificació inicial indicava un ús forestal, calia analitzar la Fracció de cabuda coberta (Fcc) de les distintes cobertures. S'analitzava, en primer lloc, la FCC ocupada per arbrat mitjançant una plantilla predefinida. A continuació, s'estimava el percentatge de matoll, i finalment, el de pastura i afloraments rocosos. Un cop obtingudes aquestes dades, es procedia a determinar quina era la cobertura dominant dins de la parcel·la (*IFN4, 2022*).

Totes aquestes dades han estat introduïdes en un full de càlcul (Microsoft Excel), estructurat com a base de dades primària, on s'ha realitzat el desglossament detallat per parcel·la.

Un cop completada la fotointerpretació, els resultats obtinguts han estat contrastats mitjançant la base de dades elaborada prèviament (*Delgado-Artés et al., 2022*), amb l'objectiu de reduir el marge d'error al mínim possible. Aquest procés de correcció ha contribuït també a l'afinament del criteri del fotointèrpret i a garantir la fiabilitat de les dades de referència emprades en les fases posteriors.



Il·lustració 4. Plantilla predefinida.

En una segona etapa, un cop finalitzat el procés d'ensinistrament del fotointèrpret, es va procedir a la selecció i fotointerpretació d'entre 15 i 20 parcel·les representatives de cada tipologia de cobertura i ús del sòl al llarg del territori de Castelló. Aquestes parcel·les, escollides segons criteris d'homogeneïtat interna i representativitat, han estat emprades com a mostres d'entrenament i validació per als models de *Machine Learning* aplicats a la classificació automàtica.

Una vegada identificades, aquestes parcel·les foren revisades detalladament pel fotointèrpret d'acord amb les ortofotografies de 2024 (ICV, 2024). S'assignaren els valors corresponents a les variables d'estudi i introduïren aquestes dades en un full de càlcul.


Aquest document constituí la base de dades d'entrenament que posteriorment s'empraria per alimentar l'algoritme d'aprenentatge automàtic.

Dades generades amb fotointerpretació


Les dades obtingudes mitjançant fotointerpretació constitueixen la base fonamental per a l'anàlisi comparativa i la classificació supervisada desenvolupada en aquest treball.

Parcel·les Benassal

Cobertures i usos	Nº parcel·les
FA	9
FM	11
PArP	27
HL	24
AgLS	3
AgHS	5
UR	1
Inf	1
Total	81




Taula 2. Resultats entrenament fotointèrpret. Font: elaboració pròpia.




Il·lustració 5. Parcel·les Benassal. Font: elaboració pròpia.

Parcelles Castelló

Cobertures i usos	Nº parcel·les
FA	16
FM	12
PArP	7
HL	15
AgLS	8
AgHS	5
AgLR	6
AgHR	0
UR	9
Inf	3
Ind	7
Total	88



Taula 3. Resultats entrenament algoritme. Font: elaboració pròpia.



Il·lustració 6. Parcel·les seleccionades en la província de Castelló. Font: elaboració pròpia.

Metodologia d'algoritmes aprenentatge automàtic

Selecció i preparació de materials

Per a obtenir les dades espectrals corresponents a les tesselles fotointerpretades, es van seleccionar imatges satel·litals obtingudes mitjançant la plataforma oficial del programa Copernicus que, a més de cobrir íntegrament l'àmbit d'estudi, coincidiren temporalment amb l'any de la captura de les ortoimatges utilitzades en la fotointerpretació, per garantir la consistència de l'anàlisi (*Copernicus Data Space Ecosystem, 2025*).

Es van requerir dues escenes per tal d'incloure la totalitat de les parcel·les analitzades. Es van seleccionar escenes corresponents al període estival de l'any 2024, quan l'activitat vegetativa assoleix el seu màxim, fet que n'afavoreix la detecció i classificació, atès que la resposta espectral captada pel satèl·lit és més nítida i representativa. Es va tindre en compte que les escenes seleccionades tingueren una cobertura de núvols inferior al 5 %, amb l'objectiu de minimitzar interferències atmosfèriques i l'aparició d'ombres . Les imatges seleccionades foren les següents:

Data	Escena	Percentatge núvols
18-06-2024	T30TYK	2,94%
18-06-2024	T30TYL	0,64%


Taula 4. Escenes satel·litals. Font: elaboració pròpia.

Dins d'aquestes imatges es disposa de diferents bandes espectrals amb resolucions espacials diverses. En aquest cas, es van seleccionar les bandes amb resolució de 20 metres, pel seu ventall espectral (inclou totes les bandes del sensor) i la seua resolució, que era suficient per a l'extracció de estadístiques zonals a escala de parcel·la. En canvi, les bandes de 10 metres només inclouen les bandes 2, 3, 4 i 8 (RGB i NIR), la qual cosa limitava l'anàlisi multiespectral completa (*ESA, 2015*). D'entre les bandes espectrals, cal destacar la importància de les bandes roja (banda 4) i infraroja propera (banda 8), ja que són aquelles on la resposta espectral de la vegetació es manifesta de manera més intensa, i per tant, ofereixen major sensibilitat per a la discriminació de cobertes vegetals.

Posteriorment, es van generar mosaics ràster per a cadascuna de les bandes seleccionades, unint les dues escenes per tal d'obtenir una cobertura contínua del territori.

A més de les bandes espectrals, s'han incorporat dues capes auxiliars com a variables explicatives: el Model Digital del Terreny (MDT) de 10 metres de resolució i el ràster de pendents, derivat d'aquest. La inclusió d'aquestes variables té un doble objectiu: d'una banda, identificar zones amb estructures aterraçades i de l'altra, avaluar l'altitud i la inclinació del terreny en la distribució i estat de la coberta vegetal.


Finalment, s'han elaborat diversos mapes temàtics per a representar visualment les dades de base, incloent un mapa de combinació RGB de bandes espectrals, així com representacions del MDT i de les pendents, que permeten complementar la lectura territorial.



Il·lustració 7. Imatges satel·litals Castelló. Font: elaboració pròpia.



Il·lustració 8. MDT Castelló. Font: elaboració pròpia.



Il·lustració 9. Pendents Castelló. Font: elaboració pròpia.

Càlcul d'estadístiques zonals i base de dades d'entrenament

Un cop generats els mosaics definitius, es va procedir a l'extracció d'estadístiques zonals per a cada banda espectral en relació amb les parcel·les definides prèviament mitjançant fotointerpretació.

Inicialment, es va contemplar la possibilitat d'utilitzar la funcionalitat Estadístiques zonals de la capa ràster disponible en el programa QGIS per al càlcul de les estadístiques sobre les parcel·les d'estudi. Tanmateix, aquesta eina presentava certes limitacions, ja que només permetia obtenir estadístiques bàsiques, i no incloïa alguns indicadors d'interès per a l'anàlisi, com ara la desviació estàndard o la mitjana (QGIS Docs, 2014).

Per aquesta raó, es va optar pel desenvolupament d'un script en llenguatge Python, específicament dissenyat per calcular estadístiques zonals a partir de dades ràster.

Mitjançant aquest codi, es va procedir al càlcul d'estadístiques zonals sobre diverses bandes ràster, és a dir, es van extraure indicadors com ara el valor mínim i màxim, la mitja, la mitjana, així com la desviació estàndard incloent tant imatges satel·litàries multiespectrals com ara capes d'informació topogràfica (model digital del terreny i pendents). Aquestes estadístiques es van obtenir a partir d'un conjunt de polígons vectorials —les parcel·les prèviament fotointerpretades— emmagatzemats en un arxiu de format shapefile (.shp).

Les estadístiques extretes per a cada banda i variable ràster foren posteriorment exportades a un arxiu CSV (Comma-Separated Values). Aquest fitxer estructurat i

lliurat en format Excel constitueix la base de dades d'entrada per al posterior entrenament i validació de models d'intel·ligència artificial, mitjançant l'eina de *Machine Learning Weka*. Amb l'objectiu de facilitar la consulta i l'anàlisi dels valors associats a cada parcel·la s'adjunta en els annexes.

Per tal d'il·lustrar el contingut i la interpretació de les dades recollides, es presenta a continuació un exemple representatiu d'una parcel·la, mitjançant el qual s'expliquen les principals variables incloses en el conjunt de dades. Aquestes variables comprenen valors estadístics (mitjana, mitja, desviació estàndard, mínim, màxim i nº de píxels) calculats per a cadascuna de les bandes espectrals seleccionades, així com per a les capes del Model Digital del Terreny (11) i de pendent (12). L'exemple serveix com a guia per entendre l'estructura del conjunt de dades i la seua aplicació en les etapes posteriors d'anàlisi i modelització. La parcel·la escollida com a exemple es la 147.

Banda	Mínim	Màxim	Mitja	Nº píxels	Desviació estàndard	Mitjana
1	1169	1342	1252,76	25	56,72	1251
2	1207	1603	1312,12	25	115,10	1259
3	1447	1902	1576,20	25	138,39	1516
4	1366	2014	1543,08	25	191,09	1454
5	1807	2489	1978,20	25	190,99	1895
6	2807	3115	2934,08	25	88,65	2903
7	3059	3391	3226,28	25	96,77	3193
8	3273	3601	3444,76	25	97,42	3460
9	2221	3384	2571,64	25	321,12	2449
10	1624	2570	1905,08	25	264,09	1795
11	1071	1115	1096,16	100	11,66	1097
12	11,17	32,51	22,18	100	4,66	22,48

Taula 5. Estadístiques zonals, parcel·la 147. Font: elaboració pròpia.

Anàlisi amb WEKA

Per a la classificació de les cobertures del sòl es va utilitzar el programari WEKA, que permet provar de manera intuïtiva diferents algoritmes d'aprenentatge automàtic sense necessitat de coneixements previs avançats en intel·ligència artificial. Aquesta característica el fa útil com a eina exploratòria, ja que ofereix un primer coneixement dels models que poden resultar més eficients i que, posteriorment, poden ser desenvolupats amb més detall en entorns com Python o R (*University of Waikato, 2004*).

Les dades d'entrada provenen de les estadístiques zonals obtingudes a partir de les bandes de Sentinel-2 i variables topogràfiques, exportades en format CSV. Es van provar algoritmes de diferents famílies (bayes, functions, lazy, misc, rules i trees), i la seua avaluació es va realitzar mitjançant validació creuada de 10 particions. No es van incloure els metaclassificadors, ja que es basen en la combinació o modificació de models de base que ja es troben representats dins les famílies anteriors. (*University of Waikato, 2004*).


La mètrica principal emprada va ser la precisió del model, tant per a classes generals com per a subclasses, ja que permet mesurar de manera directa el percentatge d'encerts en la classificació. A més de la precisió, per als models amb millor rendiment es van analitzar altres mètriques complementàries com la kappa (estadística global), la True Positive Rate (TPR), la False Positive Rate (FPR) i la precisió per classe, que ofereixen una visió més detallada del comportament del model.

Aplicació del model

Després dels experiments inicials amb WEKA, es va implementar l'algorisme recomanat per aplicar-lo de manera pràctica en Python. El procés inclou diverses etapes i el codi Python pot consultar-se als annexes:

1. Entrenament del model amb dades provincials. Amb les estadístiques prèviament obtingudes per a tota la província de Castelló, es va entrenar un model de classificació supervisada en Python (usant biblioteques com scikit-learn). El model utilitza els polígons de referència com a veritat de camp per a l'etiquetatge de les mostres.
2. Definició de l'àrea pilot. Es va utilitzar una quadrícula regular sobre el municipi de Benassal, emprant-lo com a cas d'estudi pilot. Aquesta quadrícula es va construir amb parcel·les de 100 × 100 metres.

3. Extracció d'estadístiques. Per a cada polígon de la quadrícula, es van calcular estadístiques descriptives de les bandes espectrals Sentinel-2 y de les capes SIG d'altitud y pendents. Per a això, es va reutilitzar el mateix codi que s'havia utilitzat prèviament per a l'extracció d'estadístiques de les parcel·les d'entrenament, assegurant la coherència entre les variables predictives del model i les parcel·les de la quadrícula.
4. Aplicació del model a Benassal. El classificador entrenat amb dades provincials es va aplicar a la quadrícula de Benassal per generar una predicció de classes de cobertura del sòl en cada parcel·la. La decisió d'aplicar el model a un municipi concret es sustenta en la falta de recursos computacionals que permetrien la generalització del model a tota la província.
5. Exportació i integració GIS. Els resultats obtinguts es van exportar a CSV i posteriorment es van unir a la capa vectorial de quadrícula a l'entorn QGIS. Això permet visualitzar i analitzar espacialment les prediccions de classificació en un format cartogràfic.



Il·lustració 10. Cobertures i usos Benassal segons algoritme. Font: elaboració pròpia.

RESULTATS I DISCUSSIÓ

La combinació entre la fotointerpretació i les tècniques d'aprenentatge automàtic ha proporcionat una base sòlida per a l'anàlisi, però també ha evidenciat la complexitat de discriminar determinades cobertures i usos del sòl. A partir de les mètriques estadístiques es poden establir comparacions entre els diferents enfocaments i justificar les decisions metodològiques adoptades.

Precisió d'algoritmes d'aprenentatge automàtic

S'han provat diversos algoritmes de classificació, amb l'objectiu d'identificar quins ofereixen un millor rendiment en funció de les característiques del conjunt de dades emprat. En la següent taula es mostren els tres models que han obtingut els millors resultats de cada família d'algoritmes. La primera columna recull el nom de cada algoritme; la segona, el tipus d'algoritme; la tercera, la precisió del model predictiu de les classes; i la quarta, la precisió del model predictiu de les subclasses.

Algoritme	Tipus	Precisió classe	Precisió subclasse
NaiveBayes	Bayes	64,36	52,87
NaiveBayesUpdateable	Bayes	64,36	47,12
NaiveBayesMultinomial	Bayes	62,06	47,12
SMO	Functions	71,26	55,17
SimpleLogistic	Functions	66,66	49,42
MultilayerPerceptron	Functions	65,51	45,97
IBk	Lazy	58,62	51,72
Kstar	Lazy	57,47	44,82
LWL	Lazy	56,32	34,48
OneR	Rules	58,62	34
Jrip	Rules	54,02	28
DecisionTable	Rules	52,87	41
LMT	Trees	65,51	49,42
HoeffdingTree	Trees	64,36	52,87
RandomForest	Trees	62,06	54,02

Taula 6. Precisió algoritmes WEKA. Font: elaboració pròpia.

Les subclasses s'han descartat perquè, segons la Taula 6, tots els models obtenien pitjors resultats quan treballaven amb subclasses que quan es reagrupaven en classes d'ordre superior.

Per exemple:

- SMO passa de 71,26% en classes a només 55,17% en subclasses.
- NaiveBayes baixa de 64,36% en classes a 52,87% en subclasses.
- RandomForest mostra una caiguda de 62,06% en classes a 54,02% en subclasses.

En general, cap dels algorismes supera el 56% de precisió en subclasses, mentre que diversos arriben per damunt del 65–71% en classes. Això demostra que el model predictiu és més robust quan s'agrupen les subclasses en categories més generals. Per aquest motiu es va descartar seguir treballant amb subclasses i es van seleccionar únicament les classes d'ordre superior per al desenvolupament del model final.

Dels algorismes aplicats a les classes, els que han demostrat la major efectivitat en la classificació, han sigut de la família Functions de WEKA (inclou regressió logística, màquines de vectors de suport i xarxes neuronals com el Multilayer Perceptron). L'única excepció és LMT, que mostra la mateixa precisió que MLP, però forma part de la família Trees.

Es va utilitzar com a primer filtre la estadística Kappa, una mètrica que no només mesura quantes vegades el model encerta les classes, sinó que també té en compte la possibilitat d'encerts que podrien passar per casualitat.

Algoritme	Estadística Kappa
SMO	0,5983
SimpleLogistic (SL)	0,5394
MultilayerPerceptron (MLP)	0,5393
LMT	0,5284

Taula 7. Estadística Kappa dels algorismes amb major precisió WEKA. Font: elaboració pròpia.

Segons la estadística Kappa es descarta l'algoritme LMT perquè el seu valor és menor que el de MLP. Aquesta mètrica ha permès diferenciar-los, ja que ambdues opcions presentaven la mateixa precisió global.

Finalment, es van comparar amb tres indicadors importants per a l'avaluació dels models: el TP rate, el FP rate i la precisió. El TP rate descriu la proporció de positius reals que el model detecta; el FP rate quantifica quants negatius es confonen com a positius; i la precisió indica quina fracció de les prediccions positives són correctes.

	SMO			SL			MLP		
Classe	TP rate	FP rate	Precisió	TP rate	FP rate	Precisió	TP rate	FP rate	Precisió
FA	0.813	0.028	0.867	0.688	0.07	0.688	0.625	0.028	0.833
AG	0.818	0.315	0.614	0.788	0.296	0.619	0.667	0.204	0.667
PArP	0	0	?	0.286	0.038	0.4	0.429	0.05	0.429
FM	0.5	0.053	0.6	0.25	0.04	0.5	0.417	0.107	0.385
UR	0.842	0.029	0.889	0.842	0.029	0.889	0.895	0.074	0.773

Taula 8. Mètriques de classificació per model i classe WEKA. Font: elaboració pròpia.

La Taula 8 mostra el rendiment dels tres models (SMO, SL i MLP) per classe en termes de TP rate, FP rate i precisió.

- Classe FA (Forestal A): TP alt en tots els models, amb precisió més alta en SMO (0.867), seguida de MLP (0.833) i SL (0.688). FP molt baix en SMO i MLP (0.028).
- Classe AG (Agrícola): TP moderat, amb SMO 0.818, SL 0.788 i MLP 0.667. FP més baix en MLP (0.204), que resulta en la millor precisió per a aquest model (0.667).
- Classe PArP: SMO no ha classificat correctament cap mostra (TP = 0). MLP té un TP de 0.429 amb precisió 0.429, mentre que SL mostra TP 0.286 i precisió 0.4.
- Classe FM (Forestal Mixte): Rendiment moderat, amb SMO TP 0.5, SL 0.25 i MLP 0.417. Precisió més alta en SMO (0.6).
- Classe UR (Urbà): TP molt alt per a tots els models, amb MLP 0.895, SMO i SL 0.842. FP baix en SMO i SL (0.029), lleugerament més alt en MLP (0.074).

Finalment, el Multilayer Perceptron ha sigut l'algoritme seleccionat, ja que, tot i no assolir la màxima precisió puntual com el SMO (SVM), ha mostrat un rendiment més equilibrat entre classes, incloses les menys representades. Aquesta capacitat d'adaptació a patrons no lineals i la seva robustesa en contextos variats justifiquen la seua tria com a model final.

MultilayerPerceptron

En general, MLP mostra un rendiment equilibrat, amb bona cobertura de totes les classes, incloses les menys representades com PArP. Un cop seleccionat l'algoritme, es va desenvolupar un codi en Python per a l'entrenament i aplicació del model de predicció. Com a resultats es va obtenir que el model té una precisió del 65,36%, tan sols un 0,15% menys que a WEKA. L'estadística Kappa va a ser de 0,5329, també amb poca diferència respecte al model entrenat a WEKA.

Classe	TP rate (%)	FP rate (%)	Precisió (%)
AG	69,70	30,30	62,16
FA	68,75	31,25	84,62
FM	50,00	50,00	46,15
PArP	14,29	85,71	20,00
UR	84,21	15,79	84,21

Taula 9. Mètriques de classificació per model i classe Python. Font: elaboració pròpia.

Comparant els resultats de classificació obtinguts mitjançant un model MLP implementat en Python i la mateixa prova realitzada en WEKA. En tots dos casos, la classe UR va mostrar el millor rendiment, amb altes taxes de veritables positius (84–89%) i precisió superior al 77%, indicant que el model identifica correctament la majoria dels casos d'aquesta classe. Les classes FA i AG també presenten un rendiment acceptable; Python mostra una precisió més alta per a FA (84,6%) mentre que WEKA millora lleugerament la precisió d'AG (66,7%). D'altra banda, FM i PArP van obtenir resultats significativament més baixos, especialment PArP, amb taxes de veritables positius del 14% i precisions del 20%, la qual cosa suggereix dificultats del model per distingir aquestes classes menys representades o amb patrons més complexos. En general, ambdós entorns presenten resultats consistents, encara que WEKA tendeix a mostrar un equilibri lleugerament millor entre taxa de veritables positius i falsos positius per a les classes de menor freqüència.

Aplicació del model

Amb les dades obtingudes mitjançant la fotointerpretació de Benassal de 2024 i les que ha generat el algoritme, s'han comparat les diverses parcel·les per a veure els percentatges de precisió. Cal esmentar, que la classe HL s'ha inclòs en AG per a facilitar el funcionament del algoritme. Els resultats complets es troben en un arxiu Excel, el qual es pot consultar en els annexes.

La Taula 10 conté la precisió per classes i la total, així com el nombre de parcel·les per classe.

Classe	Nº parcel·les	Precisió (%)
AG	31	48,4
FA	20	65,0
PArP	28	17,9
UR	2	0,0
Total	81	40,0

Taula 10. Precisió algoritme. Font: elaboració pròpia.

A més, és fonamental analitzar el comportament del model sobre les parcel·les de Benassal. En general, els resultats mostren que el 40% de les classes han estat correctament classificades. Tanmateix, cal remarcar que el fet d'encertar en aquestes parcel·les no garanteix una generalització òptima a la resta del territori. De fet, la precisió global del model se situa entorn del 65%, la qual cosa implica que existeix aproximadament un 35% de probabilitat d'error en qualsevol nova classificació.

Aquest marge d'incertesa s'evidencia clarament en la classe UR (Urbà). Si es compara el resultat del model amb una ortofoto de Benassal, s'observa que les zones urbanitzades no són identificades correctament. Açò pot deure's al fet que les mostres de la classe d'entrenament no reflectien de manera adequada les característiques espectrals i espacials d'aquest tipus de cobertura, generant així un biaix en la capacitat de predicció del model. Aquest problema és habitual en processos de classificació supervisada quan les dades d'entrenament no recullen suficient variabilitat dins d'una mateixa categoria.

CONCLUSIONS

L'objectiu principal del treball era desenvolupar un sistema escalable de classificació d'usos i cobertes del sòl a la província de Castelló, a partir d'imatges multiespectrals Sentinel-2, anàlisi zonal i algorismes d'aprenentatge automàtic entrenats amb dades de referència obtingudes per fotointerpretació. En termes generals, l'objectiu s'ha assolit: s'ha establert un flux de treball que ha permès generar mapes de cobertes del sòl actualitzats de manera replicable. La metodologia desenvolupada ha demostrat la viabilitat d'emprar dades lliures i tècniques automàtiques per a cartografiar el territori, contribuint a democratitzar l'accés a informació geogràfica actualitzada a escala regional. Es confirma que l'ús combinat de fotointerpretació i *Machine Learning* pot produir mapes detallats que orienten la presa de decisions en planificació territorial i gestió forestal.

No obstant això, els resultats també posen de manifest limitacions importants en quant a la precisió del model. La precisió global obtinguda pel millor model de classificació se situa al voltant del 65%, cosa que implica un marge d'error d'un 35% en les prediccions. Malgrat aquestes deficiències, el treball demostra la factibilitat de l'enfocament i assenyala les àrees a millorar. Es conclou que la metodologia de classificació semiautomàtica és útil i escalable, però requereix refinament per aconseguir nivells de fiabilitat més alts en tots els tipus de cobertes.

1. Protocol de fotointerpretació. S'ha desenvolupat un protocol de fotointerpretació d'ortofotografies que garanteix dades de qualitat per a l'entrenament dels models. Inicialment es va dur a terme un ensinistrament del fotointèrpret mitjançant la classificació de totes les parcel·les d'un municipi pilot (Benassal) en dues dates (2007 i 2024), aplicant una llegenda de cobertes i usos definida a partir de treballs previs. En una segona etapa, es van seleccionar parcel·les representatives de cadascuna de les categories d'ús/coberta arreu de la província per fotointerpretar-les. Les dades resultants, registrades en una base de dades, han servit de fonament per a l'entrenament i validació dels algorismes.
2. Selecció i processament d'imatges satel·litals. Es van seleccionar i processar imatges de satèl·lit Sentinel-2 per a la classificació del territori. En concret, es van descarregar escenes multiespectrals Sentinel-2A del programa Copernicus corresponents a l'estiu de 2024. Les dues escenes seleccionades es van unir per generar mosaics continus per a cadascuna de les bandes. Addicionalment, es van incorporar capes auxiliars derivades de models digitals del terreny: l'altitud i la pendent.

3. Càlcul d'estadístiques zonals i integració en base de dades. Per a cada parcel·la fotointerpretada, s'han calculat estadístiques zonals de les imatges ràster, integrant els resultats en una base de dades unificada. Es va optar per desenvolupar un script en Python per automatitzar l'extracció de múltiples estadístiques. El resultat, un dataset que ha permès l'anàlisi quantitativa i la comparació objectiva entre cobertes. Aquesta integració de dades de fotointerpretació amb estadístiques zonals constitueix un dels pilars metodològics del treball, ja que proporciona al model d'aprenentatge automàtic tota la informació necessària per al seu entrenament i validació.
4. Comparació d'algoritmes. Mitjançant el programari WEKA es van comparar diversos algoritmes de classificació per tal d'identificar la millor alternativa. Es van provar mètodes representatius de diferents famílies d'aprenentatge supervisat emprant validació creuada per a estimar la seua precisió. Es va observar que els millors rendiments es concentraven majoritàriament en la família Functions de WEKA. Per a triar el model òptim, es va utilitzar l'estadística Kappa com a mètrica discriminant addicional. Segons aquesta mètrica, l'SVM (SMO) va assolir el valor Kappa més elevat, lleugerament superior al del MLP. No obstant això, l'anàlisi detallada per classes va revelar que l'algoritme MLP oferia un equilibri millor en les precisions de categories minoritàries, a costa d'un lleuger descens en la precisió global. Es conclou que el millor model és el Multilayer Perceptron (MLP).
5. Aplicació i avaluació de l'algoritme en escenari real. Un cop seleccionat el Multilayer Perceptron, s'ha procedit a aplicar-lo en un escenari real per a avaluar-ne la funcionalitat operativa. Donades les limitacions computacionals per processar la classificació a escala provincial, es va escollir el municipi de Benassal com a àrea pilot. Es van extraure les mateixes estadístiques zonals que en el cas de les parcel·les d'entrenament. Les prediccions de classificació obtingudes pel model es van exportar a CSV i s'incorporaren a un sistema GIS per generar un mapa cartogràfic de cobertes del sòl de Benassal. Es confirma que el model pot encertar correctament una part de les classes, però també comet errors significatius en altres casos. En general, es va obtenir que un 40% de les parcel·les de Benassal van ser classificades de manera encertada respecte a la realitat observada en ortofoto. En conjunt, la prova pilot a Benassal indica que l'algoritme funciona moderadament bé en situacions conegudes, però pateix limitacions importants en generalitzar a noves zones. Tot i això, l'exercici serveix per demostrar l'aplicabilitat pràctica de la metodologia i proporciona informació per orientar futures millores de cara a incrementar la precisió de la classificació en entorns reals.

Limitacions del treball

- Mida i representativitat de la mostra d'entrenament: Només es disposa de 88 parcel·les de referència per entrenar el model, un conjunt reduït per a la varietat de condicions de la província. Algunes classes d'interès estan poc representades (urbà, conreus de regadiu herbaci) o presenten una gran heterogeneïtat interna, la qual cosa dificulta que l'algoritme n'aprenega els patrons. Aquesta manca de mostres diverses es tradueix en biaixos del model, com s'ha vist en la classe urbana a Benassal.
- Simplicitat temporal: El treball es basa en imatges d'un sol moment (estiu 2024) i no explora la informació multitemporal. Moltes cobertes (sobretot agrícoles) presenten fenologies estacionals o canvis intraanuals que podrien ajudar a diferenciar-les. En no considerar més èpoques de l'any, es perd aquesta informació temporal i el model pot confondre estadis diferents d'un mateix ús (camps agrícoles en guaret semblants a terrenys improductius).
- Restriccions computacionals: L'entrenament i l'aplicació del model s'han vist limitats per la disponibilitat de recursos. No ha estat factible generar el mapa de classificació per a tota la província de Castelló, i s'ha hagut de restringir l'aplicació a un municipi pilot. Açò limita la demostració de l'escalabilitat real del flux de treball i impedeix avaluar el comportament del model en àrees no incloses en l'entrenament.
- Fiabilitat de les prediccions i necessitat de validació: La precisió global del ~65% implica que una part de les prediccions són errònies. Especialment en classes minoritàries, el model pot etiquetar parcel·les amb usos incorrectes. Per tant, el producte final (mapes de cobertes) no és totalment fiable sense una revisió experta. Aquesta limitació obliga a fer una validació addicional dels resultats abans d'usar la informació en la gestió real.
- Abast de la metodologia i complexitat dels usos del sòl: La classificació s'ha simplificat a categories genèriques (forestal, agrícola, urbà) per raons de rendiment. Això significa que no s'està distingint, entre subtipus que podrien ser rellevants (diferenciar boscos de coníferes vs. frondoses, o conreus llenyosos vs. herbacis). Aquesta generalització és una limitació quant al detall de la informació proporcionada. Si bé es va comprovar que els models no podien predir fiablement subclasses, la absència en la sortida final redueix la utilitat de la cartografia per a aplicacions que requeririen un nivell de major detall.

Futures línies de recerca

- Augmentar i diversificar les dades d'entrenament: Recopilar més mostres de referència, ampliant la fotointerpretació a més parcel·les i incloent tots els tipus de cobertes en proporcions adequades. A més, es podrien aprofitar bases de dades ja existents (SIOSE, cadastre agrari) per extreure'n mostres addicionals que reforcen l'entrenament.
- Incorporar dades multitemporals i d'altres sensors: Utilitzar imatges de diferents èpoques de l'any (primavera, tardor) podria augmentar l'acert mitjançant les variacions estacionals. A més, integrar dades de radar Sentinel-1 proporcionaria informació complementària sobre l'estructura del terreny i la humitat, útil per distingir elements que en l'òptic poden semblar similars.
- Optimitzar i provar nous algorismes de classificació: Tot i haver seleccionat el MLP com a model final, convé investigar si ajustos de paràmetres o tècniques d'ensemble poden superar el seu rendiment. La literatura indica que classificadors com Random Forest i SVM sovint aconsegueixen precisions >80% en mapes d'usos del sòl amb dades Sentinel-2 quan es configuren apropiadament i es disposa de prou dades.

BIBLIOGRAFIA

- Avery, T. E., & Berlin, G. L. (1992). *Fundamentals of Remote Sensing and Airphoto Interpretation* (5a ed.). Macmillan/Prentice Hall.
- Amancio, D. R., Comin, C. H., Casanova, D., Travieso, G., Bruno, O. M., Rodrigues, F. A., & da Costa, L. F. (2013). A systematic comparison of supervised classifiers. *Neural Computing and Applications*, 23(1), 1-15.
- Blanco Castro, E., Costa Tenorio, M., Morla Juaristi, C., & Sainz Ollero, H. (Eds.). (1997). *Los bosques ibéricos: Una interpretación geobotánica*. Planeta.
- Borràs, J., Delegido, J., Pezzola, A., Pereira, M., Morassi, G., & Camps-Valls, G. (2017). Clasificación de usos del suelo a partir de imágenes Sentinel-2. *Revista de Teledetección*, (48), 55–66.
- Calatayud Giner, S. (1993). El regadío ante la expansión agraria valenciana: Cambios en el uso y control del agua (1800–1916). *Agricultura y Sociedad*, 67, 47–92.
- Comité Econòmic i Social de la Comunitat Valenciana. (2017). *Medi Ambient 2017 (informe anual)*.
- Copernicus Data Space Ecosystem. (2025). *Welcome to the Copernicus Data Space Ecosystem*.
- Delegido, J., Verrelst, J., Meza, C. M., Rivera, J. P., Alonso, L., & Moreno, J. (2011). Evaluation of Sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content. *Sensors*, 11(7), 7063–7081.
- Delgado-Artés, R., Garófano-Gómez, V., Oliver-Villanueva, J.-V., & Rojas-Briales, E. (2022). Land use/cover change analysis in the Mediterranean region: a regional case study of forest evolution in Castelló (Spain) over 50 years. *Land Use Policy*, 114, 105967.
- ESA. (2015). *Sentinel-2 User Handbook (bandes i resolucions)*.
- European Environment Agency (EEA). (2019). *CORINE Land Cover 2018 — Product overview & metadata*.
- IFN4. (2022). *Documentador de treball de camp (Fracció de cabida coberta, FCC i altres variables)*. Ministerio para la Transición Ecológica y el Reto Demográfico.
- Institut Cartogràfic Valencià (ICV). (2024). *Ortofotografia 2024 (RGBI, 25 cm): metadades i descàrrega*.
- Institut Cartogràfic Valencià (ICV). (2001). *Mapa topogràfic de la Comunitat Valenciana 1:25.000*.

- Institut Cartogràfic Valencià. (2007). *Ortofoto PNOA 2007 de la província de Castelló (RGB/IRG, 50 cm)*.
- Institut Cartogràfic Valencià. (2024). *Ortofoto 2024 de la Comunitat Valenciana (RGB/IRG, 25 cm)*.
- Instituto Geográfico Nacional (IGN). (2020). *SIOSE-AR: Documento técnico*.
- Instituto Geográfico Nacional / Centro Nacional de Información Geográfica. (2022). *High Resolution SIOSE — Technical Document (v1, EN) (antecedents 2005, 2009, 2011, 2014; SIOSE-AR)*.
- Piqueras, J. (1995). *Despoblación y cambio social en el medio rural valenciano*.
- Pérez Cueva, A. J. (1994). *Atlas climático de la Comunidad Valenciana, 1961–1990*.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- QGIS Documentation. (2014). *Zonal Statistics (v. 2.6: mínim, màxim, suma, recompte, mitjana, desviació estàndard, varietat, rang, variància)*.
- Rivas-Martínez, S., Asensi, A., Díez Garretas, B., & Valle, F. (2007). Mapa de series, geoserries y geopermaseries de vegetación de España. Memoria del mapa de vegetación potencial de España. Parte I. *Itinera Geobotanica*, 17, 1–436.
- University of Waikato. (2004). *WEKA Explorer user guide*. The University of Waikato.
- Witten, I. H., Frank, E., Hall, M. A., & Pal, C. J. (2016). *Data mining: Practical machine learning tools and techniques* (4th ed.). Morgan Kaufmann.

ANNEXES

Annex 1. Codi d'extracció d'estadístiques zonals

```
[37]: import geopandas as gpd
      from rasterstats import zonal_stats
      import rasterio
      import numpy as np
      import pandas as pd

[38]: # Ruta al archivo .shp
      gdf = gpd.read_file("E:/Trabajo_2024/TFG FERNANDO/TESELAS/TESELAS_CASTELLON_SELECCIONADAS.shp")

[39]: # Rutas a los archivos JP2 (una banda por archivo)
      rutas_bandas = [
          "E:/Trabajo_2024/TFG FERNANDO/IMG SAT/COMPOSITE/B1.tif",
          "E:/Trabajo_2024/TFG FERNANDO/IMG SAT/COMPOSITE/B2.tif",
          "E:/Trabajo_2024/TFG FERNANDO/IMG SAT/COMPOSITE/B3.tif",
          "E:/Trabajo_2024/TFG FERNANDO/IMG SAT/COMPOSITE/B4.tif",
          "E:/Trabajo_2024/TFG FERNANDO/IMG SAT/COMPOSITE/B5.tif",
          "E:/Trabajo_2024/TFG FERNANDO/IMG SAT/COMPOSITE/B6.tif",
          "E:/Trabajo_2024/TFG FERNANDO/IMG SAT/COMPOSITE/B7.tif",
          "E:/Trabajo_2024/TFG FERNANDO/IMG SAT/COMPOSITE/B8A.tif",
          "E:/Trabajo_2024/TFG FERNANDO/IMG SAT/COMPOSITE/B11.tif",
          "E:/Trabajo_2024/TFG FERNANDO/IMG SAT/COMPOSITE/B12.tif"
      ]

[40]: # Raster de MDT y pendiente (no aplicar mask)
      rutas_extra = [
          "E:/Trabajo_2024/TFG FERNANDO/CAPAS EXTRA/MDT_10.tif",
          "E:/Trabajo_2024/TFG FERNANDO/CAPAS EXTRA/Pendiente_10.tif"
      ]

[41]: # Ruta al raster de máscara de nubes
      ruta_mask = "E:/Trabajo_2024/TFG FERNANDO/IMG SAT/COMPOSITE/MSK_CLDPRB.tif"

[42]: # Leer la máscara y generar booleano (0=sin nube, 1=nube)
      with rasterio.open(ruta_mask) as src_mask:
          mask = src_mask.read(1)
          cloud_mask = mask > 65 # True donde hay nube

[43]: # Funciones estadísticas deseadas
      estadisticas = ["mean", "median", "std", "count", "min", "max"]

      resultados = []

[44]: # Función auxiliar para aplicar máscara
      def aplicar_mask(ruta_banda, mask_array):
          with rasterio.open(ruta_banda) as src:
              data = src.read(1)
              data = np.where(mask_array, np.nan, data) # reemplaza por nan donde hay nube
          return data
```

```
[45]: # Calcular estadísticas para bandas Sentinel-2 con máscara
for idx, ruta in enumerate(rutas_bandas, start=1):
    data_masked = aplicar_mask(ruta, cloud_mask)
    # zonal_stats acepta un ndarray como 'raster' si usamos affine y nodata
    with rasterio.open(ruta) as src:
        affine = src.transform

    stats = zonal_stats(
        gdf,
        data_masked,
        affine=affine,
        stats=estadisticas,
        nodata=np.nan,
        geojson_out=False
    )

    nombres_columnas = {key: f"b{idx}_{key}" for key in estadisticas}
    resultados_banda = pd.DataFrame(stats).rename(columns=nombres_columnas)
    resultados.append(resultados_banda)
```

```
[46]: # Calcular estadísticas para MDT y pendiente sin máscara
prefijos_extra = ["h", "m"] # h=altitud, m=pendiente

for idx, (ruta, prefijo) in enumerate(zip(rutas_extra, prefijos_extra)):
    stats = zonal_stats(
        gdf,
        ruta,
        stats=estadisticas,
        geojson_out=False,
        nodata=None
    )
    # Renombrar columnas con prefijo adecuado
    nombres_columnas = {key: f"{prefijo}_{key}" for key in estadisticas}
    resultados_banda = pd.DataFrame(stats).rename(columns=nombres_columnas)
    resultados.append(resultados_banda)
```

```
[47]: # Concatenar resultados al GeoDataFrame original
for df in resultados:
    gdf = gdf.join(df)

gdf
```

```
# Guardar CSV sin geometría ni columnas innecesarias
gdf_sin_geom = gdf.drop(columns=["geometry", "COMARCA", "MUNICIPIO"])
gdf_sin_geom.to_csv("E:/Trabajo_2024/TFG FERNANDO/estadisticas_zonales_teselas_entrenamiento.csv", index=False)
```

Annex 2. Codi model d'aprenentatge

```
# Importar librerías
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.neural_network import MLPClassifier
from sklearn.metrics import accuracy_score, classification_report, cohen_kappa_score, confusion_matrix
from sklearn.preprocessing import LabelEncoder
from sklearn.model_selection import cross_val_score, cross_val_predict
```

```
# --- Cargar la base de datos desde un CSV ---
# Supongamos que tienes un archivo "datos.csv" con las variables y la etiqueta
# La última columna será la variable objetivo (y)
data = pd.read_csv("E:/Trabajo_2024/TFG FERNANDO/estadisticas_zonales_teselas_entrenamiento.csv")

# Eliminar columnas que contienen "count" en su nombre
data = data.drop(columns=data.filter(like="count").columns)
```

```
# --- Separar variables y etiquetas ---
# X: desde la columna 5 hasta la última
X = data.iloc[:, 5:]
```

```
# y: primera columna como etiquetas (por ejemplo)
y = data.iloc[:, 4]
```

```
# --- Convertir etiquetas de texto a números ---
encoder = LabelEncoder()
y_encoded = encoder.fit_transform(y)
```

```
# --- Escalado de datos ---
scaler = StandardScaler()
X_scaled = scaler.fit_transform(X)
```

```
# --- Definir MLP ---
mlp = MLPClassifier(hidden_layer_sizes=(50, 30),
                    activation='relu',
                    solver='adam',
                    max_iter=1000,
                    random_state=50)
```

```
# --- Validación cruzada ---
scores = cross_val_score(mlp, X_scaled, y_encoded, cv=5, scoring='accuracy')
```

```
print("Accuracy por fold:", scores)
print("Accuracy promedio: {:.4f}".format(scores.mean()))
print("Desviación estándar: {:.4f}".format(scores.std()))
```

```
Accuracy por fold: [0.61111111 0.83333333 0.70588235 0.64705882 0.47058824]
Accuracy promedio: 0.6536
Desviación estándar: 0.1186
```

```
#Entrenar modelo final con todos los datos
mlp.fit(X_scaled, y_encoded)
```

```
MLPClassifier
```

```
MLPClassifier(hidden_layer_sizes=(50, 30), max_iter=1000, random_state=50)
```

```
y_pred_cv = cross_val_predict(mlp, X_scaled, y_encoded, cv=5)
report = classification_report(y_encoded, y_pred_cv, target_names=encoder.classes_)
print(report)
```

	precision	recall	f1-score	support
AG	0.62	0.70	0.66	33
FA	0.85	0.69	0.76	16
FM	0.46	0.50	0.48	12
Parp	0.20	0.14	0.17	7
UR	0.84	0.84	0.84	19
accuracy			0.66	87
macro avg	0.59	0.57	0.58	87
weighted avg	0.66	0.66	0.65	87

```
# --- Kappa global ---
kappa = cohen_kappa_score(y_encoded, y_pred_cv)
print(f"Kappa global: {kappa:.4f}")

# --- Matriz de confusión ---
cm = confusion_matrix(y_encoded, y_pred_cv)
print("\nMatriz de confusión:")
print(cm)

# --- TP rate, FP rate y precision por clase ---
report = classification_report(y_encoded, y_pred_cv, target_names=encoder.classes_, output_dict=True)

print("\nIndicadores por clase:")
for clase, metrics in report.items():
    if clase in encoder.classes_:
        tp_rate = metrics['recall'] * 100 # recall = TP / (TP + FN)
        fp_rate = 100 * (1 - metrics['recall']) # aproximación: FP rate por clase
        precision = metrics['precision'] * 100
        print(f"{clase}: TP rate={tp_rate:.2f}%, FP rate={fp_rate:.2f}%, Precision={precision:.2f}%")
```

Kappa global: 0.5329

Matriz de confusión:

```
[[23  1  4  3  2]
 [ 1 11  2  1  1]
 [ 6  0  6  0  0]
 [ 5  1  0  1  0]
 [ 2  0  1  0 16]]
```

Indicadores por clase:

AG: TP rate=69.70%, FP rate=30.30%, Precision=62.16%
 FA: TP rate=68.75%, FP rate=31.25%, Precision=84.62%
 FM: TP rate=50.00%, FP rate=50.00%, Precision=46.15%
 Parp: TP rate=14.29%, FP rate=85.71%, Precision=20.00%
 UR: TP rate=84.21%, FP rate=15.79%, Precision=84.21%

```
# --- Cargar el nuevo CSV ---
nuevos_datos = pd.read_csv("E:/Trabajo_2024/TFG FERNANDO/estadisticas_zonales_benassal_municipio.csv")
nuevos_datos = nuevos_datos.drop(columns=nuevos_datos.filter(like="count").columns)
```

```
# --- Eliminar filas con NaN ---
nuevos_datos_clean = nuevos_datos.dropna()
```

```
# --- Seleccionar columnas desde la 7 hasta la última ---
X_new = nuevos_datos_clean.iloc[:, 7:]
```

```
# --- Escalar con el scaler que ya tienes ---
X_new_scaled = scaler.transform(X_new)
```

```
# --- Predecir con el MLP ya entrenado ---
y_new_pred = mlp.predict(X_new_scaled)
y_new_pred_text = encoder.inverse_transform(y_new_pred)
```

```
# --- Añadir predicciones al DataFrame y guardar ---
nuevos_datos_clean['Prediccion'] = y_new_pred_text
```

```
nuevos_datos_clean.to_csv("E:/Trabajo_2024/TFG FERNANDO/nuevos_datos_predicciones_v2.csv", sep=';', index=False)
```

Annex 3. Punts Benassal fotointerpretats

N	_PTO	CABIDA	TESELA1																	FAfcc	FM 1234	FM sup	FM	P-Ar sup	P	HL
			FPI/FNPI	FA ₃	FA ₂	FA ₁	FA ₅	FR	FM	P-Ar	P	HL	AgLS	AgLR	AgHS	AgHR	UR	Uinf	Uind							
2230	0,5							1		1										0,125	1	0,13	0,00	0,88	0,00	
2285	1		1					1			1									0,25	0,125	0,75	0,09	0,00	0,00	0,66
2287	0,7		1					1	1											0,85	0,125	0,15	0,02	0,13	0,00	0,00
2319	0,65		1					1	1											0,15	0,625	0,85	0,53	0,32	0,00	0,00
2371	0,85			1				1			1									0,05	0,125	0,95	0,12	0,00	0,00	0,83
2372	0,3										1										0	0,00	0,00	0,00	1,00	
2373	0,4		1					1	1											0,75	0,375	0,25	0,09	0,16	0,00	0,00
2375	1												1								0	0,00	0,00	0,00	0,00	
2376	0,4		1							1										0,75		0	0,00	0,00	0,25	0,00
2407	1		1					1	1											0,05	0,375	0,95	0,35625	0,59375	0	0
2456	1			1				1	1											0,45	0,125	0,55	0,07	0,48	0,00	0,00
2457	1		1					1		1										0,15	0,125	0,85	0,11	0,00	0,74	0,00
2458	1							1		1											0,625	1	0,625	0	0,375	0
2459	1												1									0	0	0	0	0
2461	1		1					1	1											0,55	0,125	0,45	0,05625	0,39375	0	0
2462	0,4			1							1									0,15		0	0	0	0	0,85
2463	0,25		1					1		1										0,55	0,375	0,45	0,16875	0	0,28125	0
2493	1		1					1	1											0,85	0,375	0,15	0,05625	0,09375	0	0
2542	0,65										1										0	0,00	0,00	0,00	1,00	
2543	1		1					1		1										0,75	0,125	0,25	0,03125	0	0,21875	0
2544	1		1					1	1											0,25	0,125	0,75	0,09375	0,65625	0	0
2545	0,25										1										0	0	0	0	0	0
2547	1												1									0	0	0	0	0
2548	1												1									0	0	0	0	0
2549	1			1				1	1											0,35	0,625	0,65	0,40625	0,24375	0	0
2550	1		1					1	1											0,65	0,125	0,35	0,04375	0,30625	0	0
2582	1		1					1	1											0,45	0,125	0,55	0,06875	0,48125	0	0
2583	1		1					1	1											0,75	0,125	0,25	0,03125	0,21875	0	0
2584	0,65		1					1			1									0,25	0,125	0,75	0,09375	0	0	0,65625
2585	0,35			1				1	1											0,15	0,875	0,85	0,74375	0,10625	0	0
2586	0,75			1							1									0,05		0	0	0	0	0,95
2587	1																1					0	0	0	0	0
2588	0,5										1										0	0	0	0	0	1
2589	1		1								1									0,05		0	0	0	0	0,95
2590	0,5			1							1									0,15		0	0	0	0	0,85
2591	0,45			1				1			1									0,15	0,625	0,85	0,53125	0	0	0,31875
2592	0,3											1									0	0	0	0	0	0
2680	1		1					1	1											0,35	0,125	0,65	0,08	0,57	0,00	0,00
2681	1		1					1		1										0,15	0,125	0,85	0,11	0,00	0,74	0,00
2682	0,25		1								1									0,15		0	0	0	0	0,85
2683	1		1					1	1											0,25	0,125	0,75	0,09375	0,65625	0	0
2684	1			1				1	1											0,45	0,875	0,55	0,48125	0,06875	0	0
2685	1			1							1									0,15		0	0	0	0	0,85
2686	1							1	1											0,875		1	0,875	0,125	0	0
2687	1											1									0	0	0	0	0	0
2688	0,45										1										0	0	0	0	0	1
2689	1										1										0	0	0	0	0	1
2690	1															1					0	0	0	0	0	0
2691	1							1			1										0,125	1	0,125	0	0	0,875
2692	1							1		1										0,375		1	0,375	0	0,625	0
2693	1							1		1										0,375		1	0,375	0	0,625	0

TESELA 2																								
CABIDA	FPi/FNPI	FA ₃	FA ₂	FA ₁	FA ₅	FR	FM	P-Ar	P	HL	AgLS	AgLR	AgHS	AgHR	UR	Uinf	Uind	FAfcc	FM 1234	FM sup	FM	P-Ar sup	P	HL
0,5							1			1								0,375		1	0,375	0	0	0,625
																				0	0	0	0	0
0,3		1					1			1								0,15	0,125	0,85	0,10625	0	0	0,74375
0,35							1			1									0,125	1	0,125	0	0	0,875
0,15													1							0	0	0	0	0
0,7			1				1			1								0,05	0,375	0,95	0,35625	0	0	0,59375
0,6			1				1			1								0,15	0,125	0,85	0,10625	0	0	0,74375
																				0	0	0	0	0
0,6		1							1									0,25		0	0	0	0,75	0
																				0	0	0	0	0
																				0	0	0	0	0
																				0	0	0	0	0
																				0	0	0	0	0
																				0	0	0	0	0
0,6			1				1	1										0,95	0,125	0,05	0,00625	0,04375	0	0
0,75							1		1										0,125	1	0,125	0	0,875	0
																				0	0	0	0	0
0,35			1				1	1										0,25	0,125	0,75	0,09375	0,65625	0	0
																				0	0	0	0	0
																				0	0	0	0	0
0,75							1	1										0,625	1	0,625	0,375	0	0	0
																				0	0	0	0	0
																				0	0	0	0	0
																				0	0	0	0	0
																				0	0	0	0	0
																				0	0	0	0	0
0,35		1					1		1									0,65	0,125	0,35	0,04375	0	0,30625	0
0,65							1			1									0,125	1	0,125	0	0	0,875
0,25													1							0	0	0	0	0
																				0	0	0	0	0
0,5													1							0	0	0	0	0
																				0	0	0	0	0
0,5													1							0	0	0	0	0
0,55		1					1		1									0,05	0,125	0,95	0,11875	0	0,83125	0
0,7							1			1									0,625	1	0,625	0	0	0,375
																				0	0	0	0	0
																				0	0	0	0	0
0,75		1					1	1										0,85	0,125	0,15	0,01875	0,13125	0	0
																				0	0	0	0	0
																				0	0	0	0	0
																				0	0	0	0	0
																				0	0	0	0	0
0,55							1	1											0,375	1	0,375	0,625	0	0
																				0	0	0	0	0
																				0	0	0	0	0
																				0	0	0	0	0
																				0	0	0	0	0
																				0	0	0	0	0

2694	1			1	1				0,375	1	0,375	0,625	0	0	
2695	1	1		1	1				0,15	0,375	0,85	0,31875	0,53125	0	0
2739	1		1		1	1			0,15	0,125	0,85	0,10625	0,74375	0	0
2741	0,45		1		1	1			0,15	0,125	0,85	0,10625	0,74375	0	0
2742	1		1		1	1			0,35	0,125	0,65	0,08125	0,56875	0	0
2743	1			1		1			0,375	1	0,375	0	0,625	0	0
2744	1			1	1				0,375	1	0,375	0,625	0	0	0
2745	1			1			1		0,625	1	0,625	0	0	0,375	0
2746	0,65						1			0	0	0	0	0	0
2747	1		1		1		1		0,05	0,375	0,95	0,35625	0	0,59375	0
2748	1					1				0	0	0	0	0	1
2749	0,3						1			0	0	0	0	0	1
2750	1		1		1		1		0,15	0,625	0,85	0,53125	0	0,31875	0
2751	0,55		1		1	1			0,25	0,625	0,75	0,46875	0,28125	0	0
2752	1			1	1				0,375	1	0,375	0,625	0	0	0
2753	0,6							1		0	0	0	0	0	0
2754	1			1	1				0,625	1	0,625	0,375	0	0	0
2802	0,55		1		1		1		0,25	0,125	0,75	0,09375	0	0	0,65625
2803	1			1	1				0,375	1	0,375	0,625	0	0	0
2804	1			1		1			0,125	1	0,125	0	0	0,875	0
2805	1			1		1			0,375	1	0,375	0	0	0,625	0
2806	1			1		1			0,375	1	0,375	0	0,625	0	0
2807	0,3		2		1	1			0,05	0,375	0,95	0,35625	0	0,59375	0
2808	1		1		1		1		0,15	0,125	0,85	0,10625	0	0	0,74375
2809	1			1	1		1		0,55	0,625	0,45	0,28125	0	0,16875	0
2810	1		1		1	1			0,25	0,375	0,75	0,28125	0,46875	0	0
2811	1					1				0	0	0	0	0	1
2812	1			1	1				0,15	0,375	0,85	0,31875	0,53125	0	0
2861	1		1		1	1			0,25	0,375	0,75	0,28125	0,46875	0	0
2870	1		1		1		1		0,05	0,375	0,95	0,35625	0	0,59375	0

										0	0	0	0	0	0
										0	0	0	0	0	0
										0	0	0	0	0	0
0,55			1		1				0,125	1	0,125	0	0	0,875	0
										0	0	0	0	0	0
										0	0	0	0	0	0
										0	0	0	0	0	0
0,35					1					0	0	0	0	0	1
										0	0	0	0	0	0
										0	0	0	0	0	0
0,7					1					0	0	0	0	0	1
										0	0	0	0	0	0
0,45			1		1				0,125	1	0,125	0	0	0,875	0
										0	0	0	0	0	0
0,4						1				0	0	0	0	0	0
										0	0	0	0	0	0
0,45			1		1		1		0,55	0,125	0,45	0,05625	0	0	0,99375
										0	0	0	0	0	0
										0	0	0	0	0	0
										0	0	0	0	0	0
0,7						1				0	0	0	0	0	1
										0	0	0	0	0	0
										0	0	0	0	0	0
										0	0	0	0	0	0
										0	0	0	0	0	0
										0	0	0	0	0	0
										0	0	0	0	0	0

Annex 4. Dades de referència fotointerpretades

FM	FA	AGLS	AGHS	AGLR	AGHR	PArP	HL	URInd	URResid	URInfra
420	11	1984	323	745	6910	267	51	5632	2736	5936
1148	13	1997	1560	744	1162	128	498	5633	4661	5858
1149	19	1999	2033	746	2019	76	565	5634	5040	6757
1588	29	481	2107	5226		1748	406	6817	5507	
1928	58	3663	2362	5563		2452	980	6635	5506	
2725	91	3989		5935		2866	739	6004	5792	
2955	2583	6039				2806	1793	5784	6217	
3018	147	741					1724		6728	
2608	348						6003		6629	
1218	2431						6756			
3066	3392						1864			
3495	4516						3444			
	4647						439			
	4774						898			
	3624						1102			
	3754									

Annex 5. Estadístiques zonals

Nº PTO	SUBCLAS	CLAS	h1_min	h1_max	h1_mean	h1_count	h1_std	h1_median	h2_min	h2_max	h2_mean	h2_count	h2_std	h2_median	h3_min	h3_max	h3_mean	h3_count	h3_std	h3_median	h4_min	h4_max
11	CA	F	1172	1361	1251.36	25	27.6928437	1280	1186	1269	1261.40	25	35.8584826	1276	1532	1363	1647.35	25	167.7986575	1639	1652	2050
12	CA	F	1452	1723	1587.5	25	61.8767654	1601	1501	1554	1575.40	25	36.1115146	1569	1594	1601	1621.35	25	124.1028413	1607	1621	1869
13	CA	F	1284	1353	1318.2	25	46.23275983	1336	1233	1289	1281.25	25	32.47643087	1287	1332	1308	1307.18	25	50.86884815	1339	1389	1669
29	CA	F	1391	1394	1350.45	25	27.51811465	1332	1238	1349	1329.4	25	46.38951745	1325	1438	1340	1367.36	25	46.13314767	1342	1423	1731
31	LR	AD	1271	1784	1477.58	25	145.1051248	1446	1259	1521	1400.50	25	366.3693511	1393	1604	1426	1605.76	25	465.7729265	1674	1645	1651
31	CA	F	1386	1664	1527.64	25	74.8824736	1524	1244	1484	1384	25	200.4395214	1386	1444	1401	1444.35	25	174.7564621	1414	1624	1884
32	CA	F	1386	1599	1492.25	25	64.41262161	1458	1252	1398	1368.2	25	126.7215218	1386	1499	1408	1468.2	25	125.4211461	1454	1491	1744
36	CA	F	1386	1594	1473.58	25	52.74281248	1456	1269	1354	1356.50	25	86.42138635	1387	1484	1401	1467.36	25	82.55555556	1477	1544	1761
46	CA	F	1386	1523	1455.88	25	21.22760589	1405	1282	1363	1366.75	25	46.11715748	1384	1438	1402	1468.41	25	50.82281363	1439	1536	2031
207	PAU	F	1451	1594	1525.80	25	42.47871132	1512	1488	1505	1514.38	25	351.2514186	1512	1736	1519	1519	25	117.4604814	1485	1585	1767
222	AD	AD	1680	2064	1862.12	25	126.4640691	1781	1736	1862	1809	25	264.3278989	1862	2069	1948	1948.48	25	102.0231273	1939	2081	2424
363	HL	AD	1386	2161	1776.36	25	124.7265724	1727	1463	1822	1675.40	25	357.8857136	1767	1951	1821	1827.86	25	145.6471444	1871	2111	2221
406	HL	AD	1332	2017	1755.82	25	318.36	1743	1673	1861	1825.38	25	369.4326579	1815	1921	1863	1884.88	25	464.7984457	1988	2181	4381
466	HL	AD	1317	1804	1494.4	25	80.65109441	1511	1267	1379	1384.68	25	151.3634031	1361	1504	1429	1421.46	25	144.1772681	1469	1622	1427
147	CA	F	1369	1423	1395.75	25	36.72476428	1392	1287	1363	1342.12	25	115.1055459	1368	1423	1400	1405.2	25	436.386422	1436	1564	2024
139	CA	F	1323	1512	1417.49	25	4.761366217	1335	1217	1345	1321.44	25	17.48115519	1327	1411	1312	1478.35	25	39.46087617	1471	1575	1981
466	HL	AD	1225	1512	1368.65	25	85.7385286	1457	1287	1378	1326.03	25	264.3271181	1382	1478	1398	1453.6	25	177.0686876	1477	1605	2222
466	HL	AD	1364	1914	1739.45	25	119.7866168	1739	1614	1821	1802.58	25	265.7096454	1874	1974	1901	1914.76	25	369.1614894	2110	2389	431
466	HL	AD	1463	1964	1716.76	25	76.9187238	1823	1422	1687	1759.2	25	205.7758827	1865	1962	1913	1947.4	25	102.6888923	1927	1989	2260
473	CA	F	1473	1621	1547.45	25	65.42517638	1572	1459	1563	1548.52	25	121.2486619	1523	1648	1547	1613.46	25	113.1239683	1611	1771	2121
466	LS	AD	1239	1552	1396.83	25	82.86977425	1451	1254	1378	1315.8	25	157.5148889	1317	1547	1388	1429.88	25	208.1325518	1476	1551	2463
1148	CA	F	1334	1363	1348.49	25	31.38899772	1388	1311	1379	1314	25	75.0625115	1338	1468	1396	1403	25	81.62116578	1411	1739	2131
736	HL	AD	1367	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.46888776	1465	1596	1496	1509	25	91.68872343	1586	1656	1675
736	LS	AD	1363	1613	1490.78	25	22.68325548	1467	1291	1377	1407.28	25	75.468887									

42

43

s11_median	s12_min	s12_max	s12_mean	s12_count	s12_std	s12_median
738.5	21.86339625	94.84229279	32.34696435	303	6.78782763	36.5237579
889.5	2.32672686	54.3661289	38.3521729	303	11.1452481	28.2252584
487	8.648970241	32.84892324	19.8525129	303	4.32048932	18.8614218
852.5	15.5636745	38.05467224	24.8559711	303	5.58655571	29.6549552
935.3074951	9.48959558	39.53367498	18.74393928	303	8.87348925	19.2102926
898.252379	10.46645191	37.21554474	27.5385275	303	6.79137561	28.5386454
889	4.82682589	30.23989398	18.3624555	303	6.12576168	19.8165478
882	6.37937689	37.85455281	29.0249224	303	4.36889931	18.4712192
842.5	22.42543885	37.26876196	28.3139648	303	2.06388328	29.8605282
732.3120728	10.75870227	27.43354968	18.7891109	303	4.15863183	18.14572861
1580	6.37937689	29.32749758	18.8120728	303	4.50209612	19.5843314
904.7286651	3.58711623	17.38212803	7.881838911	303	2.68987505	7.62881758
804.8562383	1.28898647	15.73281547	3.620849507	303	1.523232488	3.268275873
857.7389627	9.748217654	18.467636	14.58298461	303	2.051347189	14.83094444
1087	11.176986	22.51251802	22.3848488	303	4.86628825	22.8889865
854	7.467577927	35.81269801	17.8853472	303	8.420358742	13.2143586
235.2777584	3.70222448	22.68487759	12.22787189	303	3.584334767	18.1179873
738.8838554	4.884339624	24.85585403	14.82794189	303	4.58548275	14.1173628
815.7086639	5.528826288	21.84384658	13.88589532	303	4.883429335	15.47825873
887	10.38766811	41.54181582	28.89248667	303	4.847241256	29.53815087
489	1.812795386	9.884839778	5.63938843	303	1.547847181	5.46158842
286	4.348738786	21.88339638	12.82676188	303	5.23684387	11.1141812
280	0	3.09861412	1.032458972	303	1.389576889	0
263	0	3.09861412	0.86884852	303	1.206741384	0
222	0	3.09861412	1.022984836	303	1.271464875	0
207	0	3.09861412	1.186318512	303	1.281454427	1.012756504
192	0	3.09861412	1.286888965	303	1.258888289	1.012756504
284.5	2.22498438	21.13383271	16.23578932	303	4.284231481	17.54883588
439.5	9.88483978	27.57870889	20.34287189	303	4.517847682	24.31887385
838.2389554	6.75186144	21.18913867	13.35428223	303	3.75675189	9.48123545
1171.642886	5.828888873	22.38735554	8.788518042	303	1.887193438	9.08878828
944.884879	5.428438752	42.85479128	5.87427872	303	18.08267489	1.95188825
384	0	38.83548791	7.181888438	303	4.42987633	6.943688255
384	0	5.42843875	4.276738475	303	1.617535884	4.281881281
388	1.812795386	15.82944388	8.5801135	303	2.588523335	7.487572787
1284.858841	4.378288721	8.812075638	5.88275645	303	0.84783883	5.817716527
297.557243	1.438388424	11.38893279	5.71438358	303	2.572887974	4.214884925
617.2184707	3.75844386	9.867485498	6.776714722	303	1.18324849	6.64361763
472.5865934	0.48888832	6.32182312	3.88888893	303	1.201386752	3.88888893
487.8207072	1.27840771	5.76472878	3.296390456	303	1.074867469	3.257836215
488.2548885	3.53888888	10.62020205	6.42488888	303	1.27888888	6.385722388
1284.783538	2.85247652	21.7884272	18.88888873	303	8.887651229	15.61218878
1284.474878	3.53888888	12.42388888	4.58888888	303	2.178761289	3.884888888
1176.05472	8.889113359	3.76588888	2.03888888	303	0.578703844	1.871888844
457.8388876	1.888888122	12.45884781	6.18884788	303	2.77888788	5.758883755
1	0	4.763841834	1.20214565	303	1.281877514	1.012756504
3034.025824	1.84877843	38.58888173	24.5188876	303	3.885884871	28.88887742
967.3803589	2.788442038	11.31154156	7.48844833	303	2.38588287	7.778851388
421	0.812795386	21.74315865	11.88488888	303	4.881758889	12.81703852
158	0	6.278270689	1.88121888	303	1.888882434	3.88881412
526.2388882	20.88182323	28.88267034	25.88388486	303	1.578888252	25.8888222
308	3.88861422	23.27322667	11.22434362	303	4.88851545	8.258881422
274.25	12.88188888	22.38889389	18.88888888	303	1.88888788	18.88888887
28.82488851	1.22824287	6.38181785	3.42375385	303	3.887884882	3.882877887
398.2388887	7.28888888	23.58888888	11.88888888	303	4.887788888	15.48881388
988.2187888	3.58158748	22.18357888	5.58842878	303	1.887725771	5.882784185
258.25	3.58888888	22.15478888	38.82888888	303	3.875887888	17.37588814
358.1151188	0.312811822	4.384872188	1.721881158	303	0.764588333	1.487265818
3888.884881	8.888671487	22.25887785	17.88882888	303	2.788275788	18.83881288
1372.838881	11.88338888	46.73872887	32.3423242	303	5.033888471	31.32772884
458.888881	4.888415188	9.81815881	7.62847538	303	0.888388473	7.788284738
305.818881	3.185811558	20.62578836	9.27438814	303	1.88884811	5.78138362
411.8388758	4.83488284	21.54770113	18.8847788	303	6.382058888	9.08138383
1141.741181	0.83888884	3.88881185	1.88273187	303	1.118815451	1.151714861
487.878885	2.588138876	17.27324392	11.5488488	303	3.88883888	11.88888881
188.232887	18.582888	32.3578888	22.3884788	303	5.84778817	22.8888888
21.2888888	0.88888888	3.88758883	1.5881888	303	0.778888887	1.88758882
35.7288782	0.888888782	3.11878881	0.88232882	303	0.27823888	0.852888272
27.8878882	0.818127848	5.48848888	0.48848888	303	0.37287547	0.75188888
15.1488887	0.81812578	7.05788881	2.78838888	303	1.88713887	1.078888212
178.388888	0.38813888	8.87884888	2.28838888	303	1.782783887	1.4728882
157.3888882	0.388888757	15.08872782	3.78824158	303	3.73745223	2.057188788
342.778888	0.88888888	8.78888883	3.18812285	303	2.888487888	3.388882238
32.57488834	0.87435188	8.808123881	1.03812788	303	2.125451357	0.788481238
77.15888133	0	3.72338137	0.78888888	303	1.88887883	0.81887588
58.7788153	0.37888488	4.878381581	1.08848888	303	1.08761288	1.781887271
27.8388882	0.834888881	1.88848888	0.88842228	303	0.27887285	0.87288888
38.84888815	0.87511128	6.21242883	1.8488488	303	1.10278884	1.145431885
35.25	0	4.38882188	0.88288212	303	1.88888887	0
488.885288	1.51128888	18.38887	9.11512451	303	2.151884812	9.115124512
24.8788888	0.838882777	3.888888871	0.8888888	303	0.58848888	0.78848882
14.3888888	0.88828881	2.8812788	0.84788881	303	0.47888888	0.781813878
12.8488882	0.78828888	1.888888888	0.58888888	303	0.38888888	0.48888888
382.884822	5.755458881	24.2284873	18.7884181	303	4.00888888	19.8488788
388.8888883	0.888288111	18.54172888	6.88881888	303	5.38817888	4.88288218
132.278882	0.888113331	21.81864807	13.7884138	303	5.21883883	9.23811384
98.878888	0.288755276	8.888888882	2.88872888	303	1.88883881	2.33888882
54.7888884	0.88178854	4.78817814	1.67887721	303	0.87887488	1.32579811

Annex 6. Validació algoritme

Nº punt	Fotointerpretació	Algoritme	Validació
2375	AgHS	AG	X
2459	AgHS	AG	X
2547	AgHS	AG	X
2753	AgHS	AG	X
2548	AgHS	AG	X
2590	AgLS	AG	X
2687	AgLS	AG	X
2746	AgLS	AG	X
2287	FA	FA	X
2461	FA	FA	X
2462	FA	UR	
2543	FA	PArP	
2550	FA	FA	X
2583	FA	FA	X
2682	FA	FA	X
2809	FA	PArP	
2493	FA	FA	X
2319	FM	FA	X
2458	FM	FA	X
2545	FM	AG	
2549	FM	FA	X
2592	FM	AG	
2684	FM	FA	X
2745	FM	FA	X
2750	FM	PArP	
2686	FM	FA	X
2754	FM	AG	
2804	FM	FA	X
2285	HL	FA	
2371	HL	FA	
2372	HL	FA	
2373	HL	AG	X
2542	HL	FA	
2584	HL	FA	
2585	HL	PArP	
2586	HL	AG	X
2589	HL	AG	X
2685	HL	FA	
2688	HL	AG	X
2689	HL	AG	X
2691	HL	FA	
2741	HL	FA	
2748	HL	FA	
2749	HL	AG	X

2751	HL	PArP	
2802	HL	FA	
2805	HL	FA	
2807	HL	FA	
2808	HL	PArP	
2811	HL	AG	X
2588	HL	FA	
2230	PArP	AG	
2376	PArP	UR	
2456	PArP	FA	
2457	PArP	FA	
2463	PArP	FA	
2544	PArP	FA	
2582	PArP	PArP	X
2591	PArP	FA	
2681	PArP	AG	
2683	PArP	FA	
2692	PArP	AG	
2693	PArP	FA	
2694	PArP	PArP	X
2695	PArP	AG	
2739	PArP	FA	
2742	PArP	FA	
2743	PArP	FA	
2744	PArP	PArP	X
2747	PArP	AG	
2752	PArP	PArP	X
2803	PArP	FA	
2806	PArP	PArP	X
2810	PArP	FA	
2812	PArP	AG	
2861	PArP	FA	
2870	PArP	AG	
2407	PArP	AG	
2680	PArP	FA	
2587	UR	PArP	
2690	UR	AG	

