

ACADEMIA OAMENILOR DE ȘTIINȚĂ DIN ROMANIA



**Monitorizarea eutrofizării din Delta Dunării pe baza
algoritmilor de tip deep learning**

- Științe geonomice -

- RAPORT Iulie – Decembrie 2025 -

Director Proiect

CS III dr. Sabin Rotaru

Membru Proiect

CS drd. Andrei Toma

Introducere

Calitatea apelor dulci este importantă pentru menținerea echilibrului ecosistemelor acvatice și pentru asigurarea resurselor necesare vieții umane și economice (*Ecosystems and Water Quality*, 2023). În ultimele decenii, aceste ecosisteme au fost afectate semnificativ de presiuni multiple, precum schimbările climatice, urbanizarea rapidă, activitățile agricole și industriale sau poluarea difuză și punctuală (Xia et al., 2016). Aceste presiuni contribuie la degradarea apelor prin eutrofizare, scăderea oxigenului dizolvat, încărcarea cu nutrienți și apariția înfloririlor alge, afectând în mod direct biodiversitatea și funcționalitatea acestora. În acest context, monitorizarea eficientă și continuă a calității apei devine o necesitate stringentă pentru protecția mediului și pentru fundamentarea politicilor de gestionare durabilă a resurselor. Obiectivele globale precum Agenda 2030 (*Transforming Our World: The 2030 Agenda for Sustainable Development* | Department of Economic and Social Affairs, n.d.) și Obiectivele de Dezvoltare Durabilă (*THE 17 GOALS* | Sustainable Development, n.d.) subliniază importanța adoptării unor metode moderne, rapide și fiabile de monitorizare care să ofere date relevante, în timp util, pe suprafețe extinse.

Calitatea apelor din Delta Dunării este influențată semnificativ de aportul de poluanți transportați de fluviul Dunărea, care traversează multiple regiuni industrializate și agricole înainte de a se vărsa în Marea Neagră. Acești poluanți provin din deversări directe de ape uzate, dar și din scurgeri difuze de suprafață, adesea încărcate cu nutrienți și substanțe chimice utilizate în agricultură. Sursele de poluare pot fi atât punctuale, cât și nepunctuale, situate atât în amonte, cât și în aval, ceea ce face ca monitorizarea și controlul calității apei în această zonă să fie o provocare de ordin regional. Delta Dunării este un ecosistem de o importanță ecologică deosebită, fiind protejat prin multiple reglementări naționale și internaționale, inclusiv ca Sit al Patrimoniului Mondial UNESCO, Rezervație a Biosferei și Zonă Umedă de Importanță Internațională conform Convenției Ramsar.

Metodele tradiționale de monitorizare, bazate pe prelevarea de probe și analize de laborator, asigură măsurători de înaltă precizie, dar sunt adesea costisitoare, consumatoare de timp și limitate în capacitatea de acoperire spațială și temporală (Liu et al., 2020; Llodrà-Llabrés et al., 2023; Zhang et al., 2024). Accesul dificil la anumite corpuri de apă, mai ales în regiuni izolate sau greu accesibile, reduce considerabil frecvența măsurătorilor și capacitatea de a surprinde variațiile rapide ale parametrilor de calitate. Teledetecția satelitară oferă o soluție

complementară valoroasă, furnizând observații frecvente, pe suprafețe mari, și permițând analiza dinamicii spațiale și temporale a apei într-un mod eficient și reproductibil. Deși nu poate înlocui complet monitorizarea in situ, teledetecția permite extinderea și completarea bazelor de date existente, contribuind la o mai bună înțelegere și anticipare a proceselor ecologice.

Parametrii fotosensibili ai calității apei, precum clorofila-a (Chl-a), materia organică dizolvată colorată (CDOM), solidele în suspensie totale (TSS) și turbiditatea, pot fi monitorizați eficient cu ajutorul imaginilor multispectrale, deoarece prezintă semnături spectrale distincte (Ali et al., 2024; Atton Beckmann et al., 2025; Cao et al., 2022; Guan et al., 2020). Clorofila-a este un indicator esențial al biomasei algale și al gradului de eutrofizare, fiind adesea utilizată în calculul indicelui stării trofice (TSI), împreună cu parametri precum fosforul total și adâncimea discului Secchi. Clorofila are o reflectanță caracteristică în domeniul verde și infraroșu apropiat (NIR) și o absorbție ridicată în benzile albastră și roșie, proprietăți care permit estimarea sa prin metode spectrale. Oxigenul dizolvat (DO), un alt parametru esențial, reflectă capacitatea ecosistemului de a susține viața acvatică și este esențial pentru evaluarea stării ecologice generale a apei.

Misiunile Sentinel-2 și Landsat-8/9, prin senzorii lor multispectrali avansați (MSI și OLI), oferă date de înaltă calitate, calibrate și fiabile, esențiale pentru analiza parametrilor optici ai apei (Poddar et al., 2019). Sentinel-2, parte a programului Copernicus, pune la dispoziție o combinație optimă de rezoluție spațială (până la 10 metri), acoperire spectrală (13 benzi în domeniile vizibil, NIR și SWIR) și frecvență de reobservare (aproximativ cinci zile), ceea ce îl face extrem de util pentru monitorizarea dinamică a corpurilor de apă, inclusiv a celor de mici dimensiuni. Reflectanța algală în jurul lungimii de undă de 705 nm, în special în banda red-edge, este deosebit de relevantă pentru detectarea înfloririlor algale, oferind posibilitatea de a dezvolta algoritmi de inversie eficienți pentru estimarea concentrației de clorofilă-a.

Dezvoltările recente în domeniul prelucrării imaginilor și al inteligenței artificiale au dus la apariția unor metode tot mai performante pentru extragerea și analiza informațiilor din datele satelitare. Modelele de tip rețea neuronală profundă, precum U-Net, permit segmentarea semantică detaliată a imaginilor și pot fi utilizate pentru clasificarea zonelor acvatice în funcție de gradul de eutrofizare sau prezența poluanților (Deng et al., 2024). În paralel cu modelele empirice, semi-analitice și analitice, aceste abordări bazate pe învățare automată

oferă o capacitate crescută de generalizare și de adaptare la variabilitatea spectrală și spațială specifică ecosistemelor acvatice.

Proiectul își propune să exploreze potențialul datelor satelitare multispectrale, pentru monitorizarea parametrilor optici ai calității apei în ecosisteme vulnerabile. Se urmărește integrarea datelor satelitare cu tehnici avansate de procesare automată, pentru estimarea clorofilei-a, a turbidității, a materialelor în suspensie și a materiei organice dizolvate, cu aplicație directă în evaluarea stării lacurilor din Delta Dunării.

1. Date in situ

Delta Dunării constituie una dintre cele mai vaste și valoroase zone umede din Europa, cu o dinamică geomorfologică complexă, influențată de interacțiunea dintre debitele fluviului și procesele marine din Marea Neagră. Diversitatea proceselor hidrologice, de la aportul fluvial până la efectele valurilor și ale curenților litorali, a modelat un teritoriu eterogen, alcătuit din două mari unități: o zonă dominată de influența râurilor, în partea vestică, și o zonă cu caracteristici fluvio-marine, localizată spre est și sud, separate de o serie de formațiuni nisipoase extinse.

Datele in situ (Figura 1) au fost colectate în cea mai mare măsură din depresiunea Lumina-Roșu, care cuprinde un complex de lacuri (Roșu, Roșuleț, Puiu, Lumina, Puiulet, Macovei și Iacub) ce prezintă un grad ridicat de conservare naturală. Aceste lacuri sunt conectate indirect cu brațul Sulina printr-o rețea de canale hidrotehnice, care reglează schimburile de apă, dar reduc semnificativ influența directă a aluviunilor fluviale. Principalele fluxuri hidrologice provin din canalul Crișan-Caraorman, responsabil de alimentarea cu apă a lacurilor Roșu și Puiu, în timp ce partea nordică a sistemului primește aport din canalul Vătafu-Imputita. Evacuarea apelor se realizează prin canale precum Busurca și Tătaru, fiind completată de alte canale de conexiune secundare.




Figura 1. Sursele de prelevare a datelor in situ.

Această zonă se remarcă prin diversitatea formelor de stres la care este expusă, atât de origine naturală, cât și generată de activități umane, constituind astfel un cadru ideal pentru preluarea probelor care vor fi utilizate în cadrul evaluării calității apei și a sensibilității ecosistemelor la factori de presiune variabili.

Starea calității apei în cadrul fiecărui lac este determinată în principal de dinamica hidrologică locală, în special de volumul de apă care intră și iese din sistemul lacustru. Această dinamică este influențată de variațiile naturale ale debitului fluviului Dunărea, de regimul precipitațiilor și de procesele de evaporare. Pentru a surprinde variabilitatea sezonieră a acestor influențe, campaniile de prelevare a probelor de apă s-au desfășurat anual, pe o durată de aproape 15 ani, utilizând nava de cercetare „Istros” a Institutului Național de Geologie și Geoecologie Marină – GeoEcoMar din București. Un exemplu de sistem de prelevare se poate observa în figura 2. În cadrul acestei cercetări, o serie de parametri esențiali ai calității apei au fost monitorizați atât în teren, cât și în laborator, pentru a evalua caracteristicile fizico-chimice ale lacurilor studiate. Măsurătorile in situ au fost realizate la fiecare punct de eșantionare, utilizând un multiparametru portabil de teren WTW 3630 IDS, care a permis determinarea directă a temperaturii, pH-ului, oxigenului dizolvat, conductivității electrice și a concentrației totale de solide dizolvate.

Analizele de laborator au fost efectuate ulterior în vederea determinării concentrațiilor unor compuși chimici și substanțe nutritive relevante pentru starea ecologică a apei. Pentru aceste determinări s-au folosit spectrofotometrul UV-VIS Hach DR6000 și turbidimetrul portabil

Hach 2100. Parametrii analizați au inclus azotul nitric și nitros ($\text{NO}_2\text{-N}$, $\text{NO}_3\text{-N}$), fosforul sub formă de fosfați ($\text{PO}_4\text{-P}$), siliciul dizolvat, clorofila-a, carbonul organic total (TOC), sulfații, turbiditatea, solidele în suspensie totale (TSS), sulful și hidrogenul sulfurat, precum și prezența detergenților sintetici.

Zeci de probe au fost procesate anual, iar rezultatele urmează să intergrate în sistemul de machine learning pentru clasificarea imaginilor satelitare.

2. Exemplu date in situ utilizate - Concentrația de clorofilă-a și variabilitatea sezonieră - prezentarea datelor pentru anul 2022

În perioada cu debite ridicate (mai 2022), valorile clorofilei-a s-au menținut sub pragul de 25 $\mu\text{g/L}$, asociat cu prima clasă de calitate a apei (foarte bună), conform criteriilor de evaluare. Intervalele de variație au fost relativ restrânse: în secțiunile de control valorile au fost cuprinse între 4,11 și 16,08 $\mu\text{g/L}$, în Lacul Roșuleț între 2,25 și 3,86 $\mu\text{g/L}$, în Lacul Roșu între 1,71 și 11,89 $\mu\text{g/L}$, iar în Lacul Puiu între 1,22 și 13,00 $\mu\text{g/L}$. Aceste concentrații reduse sunt asociate cu condiții hidrologice și climatice tipice sezonului de primăvară, cum ar fi temperaturi mai scăzute și precipitații semnificative, care limitează dezvoltarea fitoplanctonului.

În contrast, în perioada cu debite scăzute (august 2022), valorile Chl-a au fost mult mai ridicate și cu o variabilitate sporită. În acea etapă, concentrațiile în secțiunile de control au variat între 5,36 și 53,07 $\mu\text{g/L}$, în timp ce în lacurile analizate au fost înregistrate valori semnificativ mai mari: Lacul Lumina (37,36–121,09 $\mu\text{g/L}$), Puiulet (90,45–142,94 $\mu\text{g/L}$), Macovei (49,62–125,66 $\mu\text{g/L}$) și Iacub (74,22–301,55 $\mu\text{g/L}$). Aceste creșteri pot fi atribuite, în principal, temperaturilor ridicate din timpul verii, care favorizează procesele de remineralizare a substanțelor nutritive și susțin producția primară.

Valorile solidei în suspensie totală (TSS, exprimate în mg/L) au prezentat o variație semnificativă între cele două campanii de prelevare, influențate de regimul hidrologic diferit. În perioada cu debite ridicate ale fluviului Dunărea (mai 2022), concentrațiile de TSS au fost în general scăzute, încadrându-se sub pragul de 40 mg/L , considerat acceptabil pentru apele dulci din punct de vedere ecologic. În această etapă, probele au indicat următoarele intervale

de variație: 12–39 mg/L în secțiunile de control, 3–6 mg/L în Lacul Roșuleț, 3–10 mg/L în Lacul Roșu și 3–16 mg/L în Lacul Puiu. Valorile reduse pot fi asociate cu diluarea cauzată de volumurile mari de apă și cu scăderea proceselor de resuspensie a particulelor din sedimente.

În schimb, în perioada caracterizată de debite scăzute (august 2022), s-a observat o creștere considerabilă a concentrațiilor de TSS în toate lacurile investigate, multe dintre valorile înregistrate depășind pragul de 40 mg/L. În această etapă, probele au indicat următoarele valori: 18–43 mg/L în zonele de control, 31–78 mg/L în Lacul Lumina, 50–84 mg/L în Lacul Puiulet, 25–53 mg/L în Lacul Macovei și 32–93 mg/L în Lacul Iacob. Această creștere poate fi pusă pe seama evaporării accentuate în perioada secetoasă, a circulației mai reduse a apei și a intensificării activităților biologice și fizice care favorizează suspensia particulelor în coloana de apă.

3. Analiza contextului geografic – Acoperirea terenurilor

Progresul tehnologiilor de teledetecție și al metodelor de învățare automată permite în prezent o monitorizare detaliată și multi-temporală a Deltei Dunării. Programul Landsat pune la dispoziție o arhivă extinsă de imagini satelitare începând cu anii 1980, oferind astfel o perspectivă unică asupra evoluției pe termen lung a acoperirii terenurilor. În cadrul acestui studiu au fost generate compozite multi-anuale Landsat pentru anii 1985, 1995, 2005, 2015, 2021 și 2025, utilizând date provenite din misiunile Landsat 5 TM, Landsat 8 OLI și Landsat 9. Imaginile au fost armonizate spectral prin selectarea și scalarea benzilor optice comune (BLUE, GREEN, RED, NIR, SWIR1, SWIR2), asigurând comparabilitatea în timp între diferitele generații de senzori. Pe baza acestor imagini au fost calculați indicatori spectrali relevanți pentru ecosistemele de zone umede și pentru clasificarea acoperirii terenurilor, precum NDVI (indice de vegetație), NDMI (indice de umiditate a vegetației), MNDWI (indice modificat de apă) și NDBI (indice pentru zone construite). Pentru fiecare an analizat s-au creat compozite mediene estivale pentru intervalul iunie–septembrie, după mascarea norilor și a umbrelor, iar rastererele de predictor au fost exportate la o rezoluție de 30 m pentru prelucrări ulterioare.

Preprocesarea datelor satelitare a fost realizată în mediul Google Earth Engine, utilizând funcții dedicate pentru filtrarea colecțiilor Landsat în funcție de an, sezon și regiune de

interes (Delta Dunării și zona Sacalin), pentru mascarea norilor pe baza QA_PIXEL, pentru scalarea reflectanțelor de suprafață la valori fizice, pentru calculul indicilor de vegetație și apă și pentru generarea și exportul compozitelor multi-anuale de predictor. Pentru anul de referință 2021, acești predictor Landsat au fost integrați cu produsul global ESA WorldCover 2021, inițial la 10 m și ulterior resamplat la 30 m, pentru a crea o hartă de referință folosită la antrenarea unui model de segmentare semantică. Legenda utilizată în studiu a fost agregată în cinci clase tematice majore, relevante pentru Delta Dunării: zone construite, terenuri agricole, vegetație naturală (păduri, arbuști, vegetație de zonă umedă), vegetație uscată sau rară (pajiști uscate, soluri goale) și apă.

Pe baza acestor date a fost dezvoltat un flux de lucru în Python, folosind biblioteci precum rasterio, GeoPandas, PyTorch și segmentation_models_pytorch. Acest flux a cuprins generarea de patch-uri de antrenare de 256×256 pixeli limitate la zona de interes, normalizarea bandelor spectrale pe baza statisticilor calculate în interiorul ROI, definirea și antrenarea unui model de tip U-Net cu encoder ResNet-101, utilizând o funcție de pierdere de tip focal loss și ponderi pe clasă adaptate distribuției dezechilibrate a etichetelor, precum și aplicarea modelului pe întreaga scenă Landsat 2021 printr-o predicție de tip „sliding window” cu suprapunere, astfel încât tranzițiile la marginile patch-urilor să fie mai line. Acest nucleu metodologic de învățare profundă furnizează hărți de acoperire a terenurilor pentru anul 2021, care au fost ulterior transferate și calibrate pentru anii istorici și cei recentți, rezultând un lanț temporal coerent de produse land cover pentru perioada 1985–2025.

3.1 Metodologie

Metodologia propusă integrează teledetecția satelitară multi-temporală, produse globale de acoperire a terenurilor și tehnici avansate de învățare profundă, cu scopul de a obține și analiza hărți de acoperire a terenurilor în Delta Dunării pentru mai multe momente cheie din intervalul 1985–2025. Fluxul de lucru cuprinde selecția și preprocesarea imaginilor Landsat în Google Earth Engine, generarea etichetelor de antrenare pe baza produsului ESA WorldCover 2021, antrenarea unui model de segmentare semantică de tip U-Net cu encoder ResNet-101, inferența multi-anuală și generarea hărților de clasă pentru anii analizați, precum și reproiecția și pregătirea datelor în sistemul UTM 35N pentru analize spațiale ulterioare.

3.2 Date și regiune de interes

Regiunea de interes include Delta Dunării și zona Sacalin, definită printr-un feature collection vectorial importat în GEE. Această geometrie este utilizată pentru filtrarea spațială a colecțiilor Landsat, pentru decuparea compozitelor satelitare și pentru limitarea analizelor ulterioare (etichete, predicții, statistici) la interiorul Deltei. Pentru componenta de teledetecție au fost utilizate colecțiile Landsat 5 TM (LANDSAT/LT05/C02/T1_L2) pentru anii anteriori lui 2011, Landsat 8 OLI (LANDSAT/LC08/C02/T1_L2) pentru perioada recentă, Landsat 9 (LANDSAT/LC09/C02/T1_L2) pentru anii mai mari sau egali cu 2021, precum și produsul global ESA WorldCover 2021, cu rezoluție de 10 m, folosit ca sursă de etichete de referință.

3.2 Preprocesarea imaginilor Landsat în Google Earth Engine

Pentru fiecare an analizat (1985, 1995, 2005, 2015, 2021, 2025) a fost definit un interval sezonier comun, cuprins între 1 iunie și 30 septembrie, pentru a reduce variabilitatea sezonieră și pentru a evita perioadele cu acoperire nivală sau condiții atmosferice instabile. În Google Earth Engine au fost implementate funcții de preprocesare specifice fiecărei generații de senzori. Pentru Landsat 5 TM, prelucrarea a inclus mascarea norilor și a umbrelor de nori pe baza bitilor 3 și 4 din banda QA_PIXEL, scalarea reflectanțelor de suprafață folosind factorul standard ($DN * 0,0000275 - 0,2$) și redenumirea benzilor optice într-un set comun: BLUE, GREEN, RED, NIR, SWIR1, SWIR2. Pentru Landsat 8 și 9 s-a aplicat aceeași mască de nori și umbre pe QA_PIXEL, au fost selectate benzile SR_B2–SR_B7, scalate identic și armonizate denumirile benzilor la același set spectral. Asupra acestor compozite optice armonizate au fost calculați patru indici spectrali relevanți pentru zone umede și acoperirea terenurilor, respectiv NDVI, NDMI, MNDWI și NDBI, cu formulele standard pentru vegetație, umiditatea vegetației, apă de suprafață și zone construite. Pentru fiecare an, imaginile filtrate au fost agregate prin mediana valorilor pixelilor din intervalul sezonier, rezultând compozite mediene estivale decupate la ROI, care includ benzile spectrale armonizate și indicii calculați. Aceste imagini au fost exportate din GEE ca rastere de predictor la rezoluția de 30 m, de tip DanubeDelta_Landsat[year]_predictors_30m.tif.

Generarea etichetelor de antrenare pe baza ESA WorldCover 2021 Pentru anul 2021, compozitul Landsat a fost combinat cu produsul ESA WorldCover 2021 pentru a crea etichete tematice destinate antrenării modelului de clasificare. Fluxul de lucru în Python, realizat cu bibliotecile rasterio, numpy și geopandas, a cuprins mai multe etape. În primul rând, WorldCover 2021, cu rezoluție de 10 m, a fost resamplat la 30 m și reproiectat pe grila Landsat 2021 prin metoda nearest neighbour, astfel încât fiecare pixel Landsat să primească o clasă WorldCover corespunzătoare, păstrându-se sistemul de coordonate al compozitului Landsat și setându-se la nodata zonele din afara ROI. În continuare, ROI-ul vectorial a fost rasterizat pe grila Landsat 2021, rezultând o mască booleană interior–exterior, utilizată atât pentru filtrarea etichetelor, cât și pentru calculul statisticilor de normalizare.

Legenda originală WorldCover a fost reclasificată într-o legendă simplificată cu cinci clase tematice principale. Zonele construite au fost asociate clasei 50, reprezentând clasa 0 în noua legendă, terenurile agricole corespunzând clasei 40, asociată clasei 1, vegetația naturală (păduri, arbuști, vegetație de zonă umedă) fiind agregată din clasele 10, 20, 90 și 95 și atribuită clasei 2, vegetația uscată sau rară (pajiști, soluri goale, lichen) provenind din clasele 30, 60 și 100 și fiind codificată drept clasa 3, iar apa, reprezentată de clasa 80, fiind asociată clasei 4. Pixelii din afara ROI sau marcați ca nodata au fost setați la valoarea 255, utilizată ca etichetă de ignorat în procesul de antrenare. Pentru fiecare bandă spectrală și indice au fost calculate media și abaterea standard exclusiv pe pixelii validați de ROI și fără valori NaN, iar benzile au fost normalizate prin z-score doar în interiorul ROI, pixelii invalizi fiind setați la 0 și ignorați la antrenare.

3.4 Antrenarea modelului de segmentare semantică U-Net ResNet-101

Modelul de clasificare spațială a fost implementat în PyTorch, utilizând biblioteca segmentation_models_pytorch și un model de tip U-Net cu encoder ResNet-101 preantrenat pe ImageNet. Arhitectura a fost adaptată pentru a primi ca intrare un număr de canale egal cu numărul de benzi (spectrale plus indici) și pentru a produce cinci clase de ieșire corespunzătoare legendelor agregate, lucrând la rezoluția de 30 m prin utilizarea de patch-uri de 256×256 pixeli.

Pentru a asigura trasabilitatea antrenării și pentru a crește diversitatea spațială a mostrelor, întregul raster Landsat 2021 și rasterul de etichete au fost împărțite în patch-uri de 256×256

pixeli, cu stride de 128 pixeli, rezultând patch-uri suprapuse, iar în setul final au fost păstrate doar patch-urile care conțineau cel puțin 10 % pixeli valizi în interiorul ROI. Setul de patch-uri a fost împărțit în proporție de 80 % pentru antrenare și 20 % pentru validare, distribuția spațială fiind utilizată implicit ca formă de stratificare. Pentru a crește robustețea modelului față de variațiile spațiale și de orientare au fost aplicate augmentări de date, precum flip orizontal și vertical și rotații la 90 de grade.

Funcția de pierdere a fost aleasă de tip Focal Loss, cu parametrul gamma egal cu 2,0, pentru a aborda distribuția dezechilibrată a claselor din interiorul ROI. Au fost calculate ponderi pe clasă pe baza frecvenței pixelilor, folosind o schemă logaritmică, cu greutate invers proporționale cu $\log(\text{count} + 1)$ și normalizare, astfel încât clasele rare, cum sunt zonele construite, să fie penalizate mai puternic atunci când sunt greșit clasificate. Pixelii cu eticheta 255 (IGNORE_LABEL) au fost excluși explicit din calculul pierderii. Optimizarea s-a realizat cu algoritmul Adam, cu o rată de învățare inițială de $1e-4$, iar rata de învățare a fost ajustată automat cu un scheduler de tip ReduceLROnPlateau, în funcție de pierderea pe setul de validare. Antrenarea s-a desfășurat pe GPU, pe parcursul a până la 200 de epoci, fiind reținut modelul cu cea mai mică pierdere pe validare.

3.5 Inferența și generarea hărților multi-anuale

După finalizarea antrenării, modelul optim a fost utilizat pentru a produce hărți de acoperire a terenurilor pentru anii 1985, 1995, 2005, 2015 și 2025. Procedura a presupus încărcarea compozitelor Landsat multi-anuale, conținând aceleași benzi și indici ca în 2021, normalizarea acestora cu aceleași statistici (medii și deviații standard) calculate pentru anul 2021, pentru a asigura coerența inter-anuală a intrărilor, aplicarea modelului pe întreaga scenă printr-o abordare de tip „sliding window”, folosind patch-uri de 256×256 pixeli cu suprapunere și medierea probabilităților de clasă în zonele de suprapunere pentru tranziții line. Ulterior a fost aplicată masca ROI pentru a seta pixelii din afara Deltei la valoarea de nodata 255. Rezultatul constă în hărți de clasă raster `prediction_[year]_classes_noholes.tif` pentru fiecare an analizat, cu o structură categorială consistentă în timp.

Reproiecția în sistem de coordonate UTM 35N și pregătirea pentru analize ulterioare Pentru a permite calculul robust al suprafețelor și integrarea facilă cu alte seturi de date geospațiale, precum limite administrative, infrastructură sau modele hidrologice, hărțile de

clasă obținute au fost reproiectate într-un sistem de coordonate proiectate, respectiv UTM zona 35N, EPSG:32635. Pentru fiecare raster de predicție multi-anuală a fost citit rasterul inițial, în CRS-ul original (de exemplu latitudine–longitudine), iar în cazul în care sistemul de coordonate nu era prezent în metadate, acesta a fost atribuit anterior, de exemplu EPSG:4326. Folosind funcția `calculate_default_transform` din `rasterio` au fost determinate noua transformare spațială, lățimea și înălțimea rasterului în EPSG:32635, profilul rasterului a fost actualizat cu noul CRS, cu transformarea și dimensiunile rezultate, cu compresie LZW, iar valoarea de nodată a fost setată explicit la 255 pentru rastelele categoricale. Reproiecția propriu-zisă a fost realizată cu funcția `reproject`, utilizând metoda `nearest neighbour`, adecvată datelor de tip clasă, pentru a evita crearea de valori intermediare artificiale, iar rasterul rezultat a fost salvat cu nume de tip `prediction_[year]_classes_noholes_utm35.tif`. Aceste rastele reproiectate sunt utilizate ulterior pentru calculul suprafețelor și al statisticilor pe clase, precum și pentru analize de tip `change detection`, care urmăresc tranzițiile între clase între anii analizați.

3.6 Rezultatele privind dezvoltarea și validarea modelului pentru anul 2021

Modelul a fost antrenat utilizând compozitele Landsat 2021 în combinație cu produsul ESA WorldCover 2021, care a fost resamplat la 30 m, reproiectat în UTM 35N, reîncadrat într-o legendă cu cinci clase tematice și folosit atât ca set de referință (`ground truth`), cât și pentru evaluarea finală. Datele de referință, ilustrate schematic în Figura 1, prezintă reflectanța Landsat și etichetele WorldCover reclasate, oferind baza vizuală pentru înțelegerea modului în care modelul învață structura terenului.

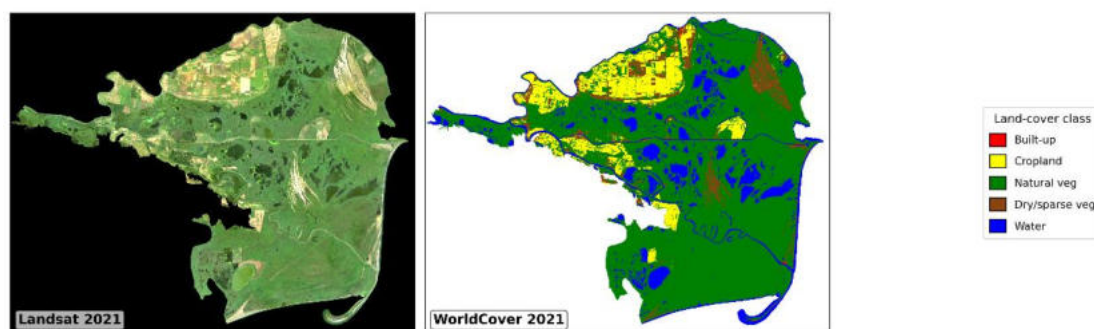


Figura 1. Datele de referință pentru model.

Evaluarea pe datele din 2021 indică performanțe excelente și robuste ale modelului. Acuratețea globală (Overall Accuracy) atinge valoarea 0,9590, adică 95,90 %, iar indicele mediu de suprapunere (Mean Intersection over Union, mIoU) are valoarea 0,7805, respectiv 78,05 %. La nivel de clasă, modelul obține pentru zona construită un IoU de 0,4384, o precizie de 0,6104, un recall de 0,6088 și un F1-Score de 0,6096, pentru un număr de 9.752 pixeli. Pentru terenurile agricole IoU este 0,8668, precizia 0,9148, recall-ul 0,9429 și F1-Score-ul 0,9286, pe 576.694 pixeli. Vegetația naturală este caracterizată de un IoU de 0,9499, precizie de 0,9777, recall de 0,9709 și F1-Score de 0,9743, pe 4.004.158 pixeli. Vegetația uscată sau rară are un IoU de 0,7210, o precizie de 0,8199, un recall de 0,8568 și un F1-Score de 0,8379, pe 336.387 pixeli. Clasa apă prezintă un IoU de 0,9263, o precizie de 0,9649, un recall de 0,9585 și un F1-Score de 0,9617, pe 719.963 pixeli. Aceste valori indică o capacitate ridicată a modelului de a separa vegetația naturală, terenurile agricole și apa, precum și de a distinge clase cu semnătură spectrală similară, cum sunt vegetația uscată și vegetația naturală. Figura 2 confirmă că distribuția claselor este păstrată aproape identic între harta de referință și predicții, sugerând absența unor bias-uri sistemice.




Figura 2. Metrice de evaluare.

Matricea de confuzie, prezentată în Figura 3, arată că marile clase dominante, respectiv vegetația naturală, terenurile agricole și apa, sunt identificate corect în proporții cuprinse între 94 % și 97 %. Confuziile principale apar între vegetația naturală și vegetația uscată, fenomen explicat prin tranzițiile naturale din zonele cu stuf uscat sau vegetație degradată și prin amestecul spectral caracteristic zonelor umede în perioada estivală. Acest rezultat arată că modelul surprinde foarte bine structura ecosistemelor umede, fără tendințe de supraînvățare, chiar în condiții de semnături spectrale apropiate.

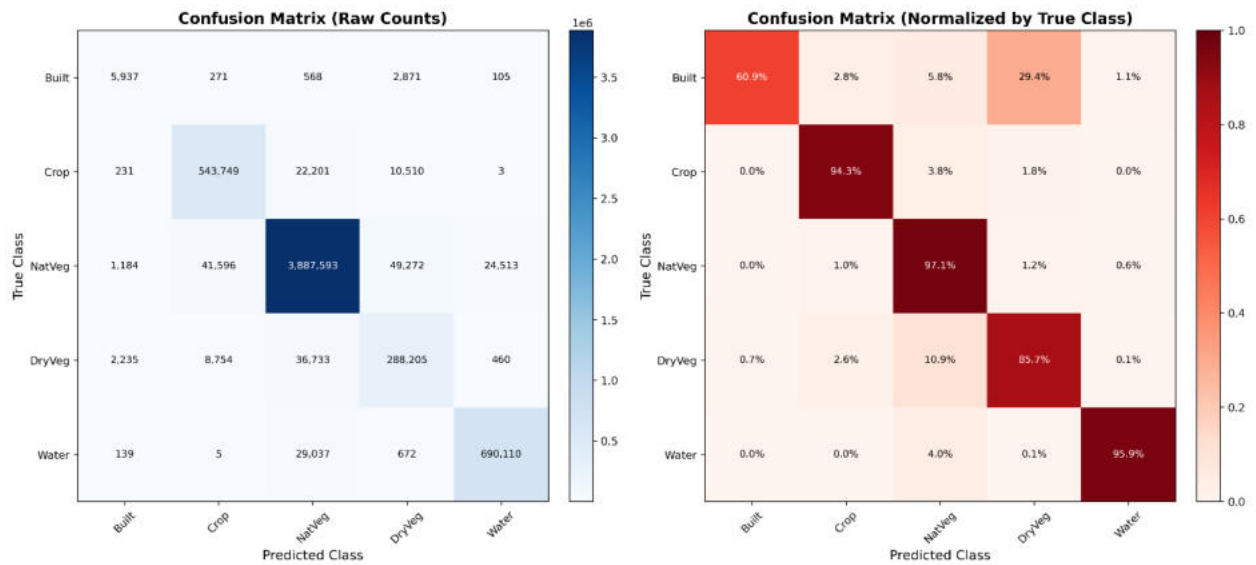


Figura 3. Matrice de confuzie.

Validarea vizuală prin triplete de tip intrare–referință–predicție, ilustrate în Figura 4, evidențiază o potrivire foarte bună a limitelor dintre agricultură, vegetație naturală și apă, precum și cazuri în care modelul corectează etichete WorldCover eronate sau zgomotoase, sugerând o înțelegere spectrală mai coerentă în zone complexe. Curbele de antrenare și validare ale modelului, prezentate în Figura 5, arată o scădere stabilă a pierderii, o stabilizare a acurateții în jurul valorii de 95 % și o aliniere bună între curbele de antrenare și de validare, ceea ce confirmă robustețea modelului și capacitatea sa de generalizare.




Figura 4. Referință vs predicție.




Figura 5. Curbe de antrenare/validare model.

3.7 Rezultatele multi-temporale pentru perioada 1985–2025

Modelul validat pe anul 2021 a fost aplicat retroactiv și prospectiv pe compozitele Landsat pentru anii 1985, 1995, 2005, 2015 și 2025. Hărțile obținute, sintetizate în Figura 6, prezintă o coerență spațială ridicată, iar Figura 7 ilustrează imaginile satelitare Landsat care au stat la baza clasificărilor. Analiza suprafețelor pe clase, reprezentată în Figura 8, evidențiază dinamica celor cinci clase în interval de patru decenii. Vegetația naturală rămâne clasa dominantă, cu un maxim în jurul anului 2015 și o scădere în 2025. Terenurile agricole prezintă o dinamică oscilantă, cu o creștere puternică în 1995 și o nouă creștere în 2025. Vegetația uscată sau rară înregistrează o creștere semnificativă în 2025, asociată proceselor de uscare și degradare a vegetației. Clasa apă are o evoluție descendentă constantă pe intervalul 1985–2025, în timp ce suprafața construită rămâne global stabilă ca pondere, dar extinderea relativă este importantă raportat la dimensiunea clasei.

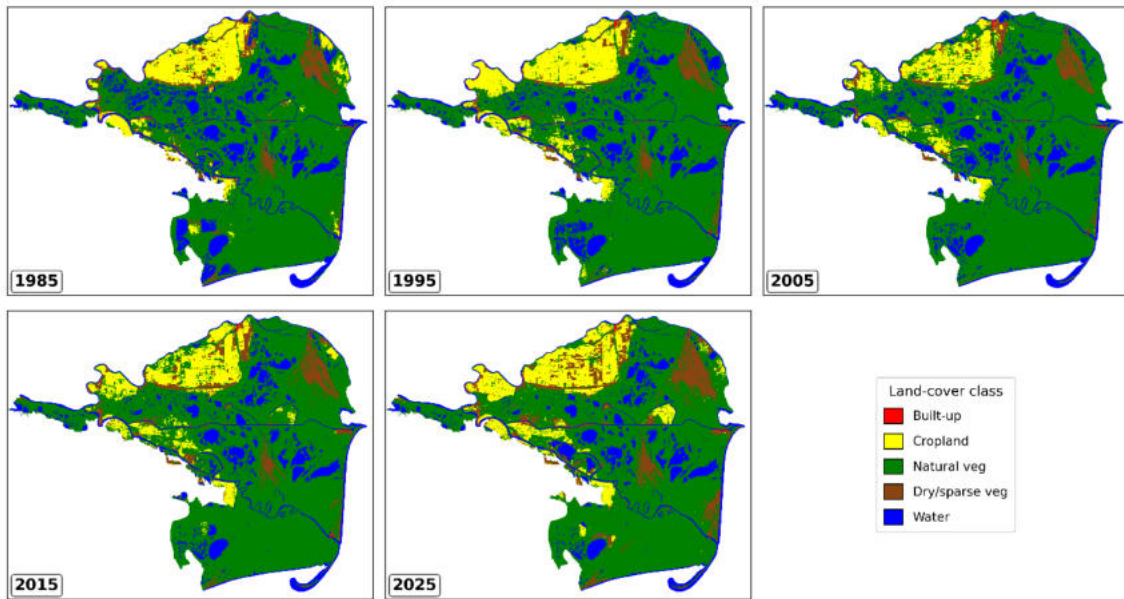


Figura 6. Hărți de acoperie a terenurilor pentru perioada analizată.




Figura 7. Imaginile satelitare Landsat utilizate pentru clasificări.

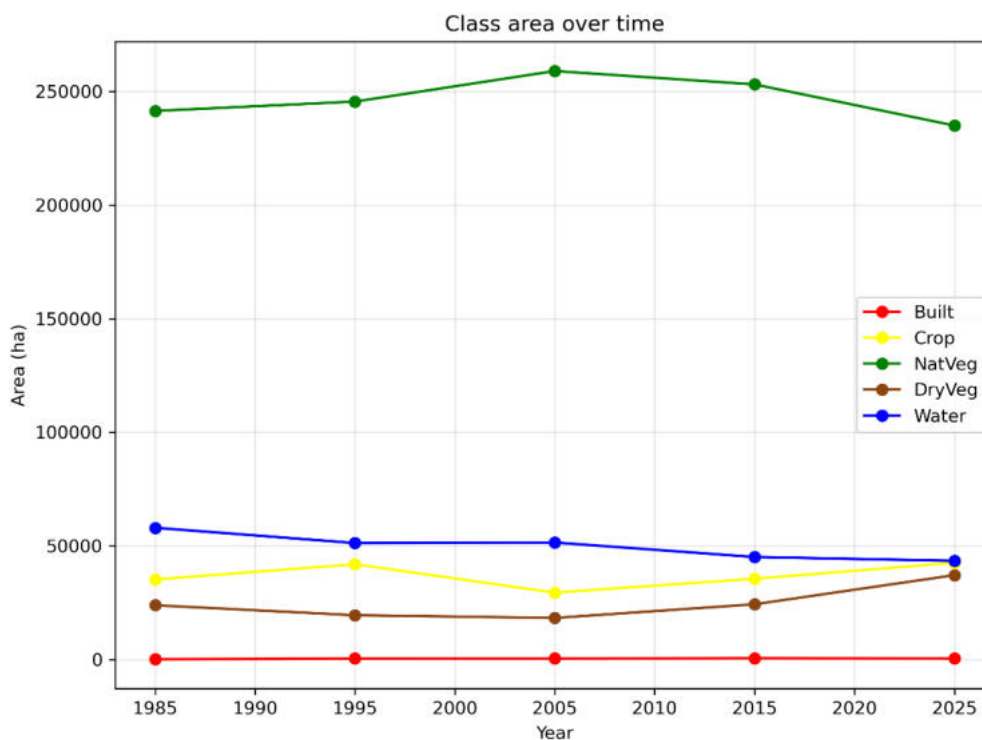


Figura 8. Dinamica claselor.

Analiza schimbărilor între 1985 și 2025, sintetizată în Figura 9, face distincția între pierderi, câștiguri și zone stabile. Se observă că vegetația naturală prezintă atât pierderi punctuale în nord și pe grinduri, cât și câștiguri în lacurile centrale și în zonele cu stuf. Terenurile agricole înregistrează multiple conversii către și dinspre vegetația naturală, reflectând presiuni antropice și dinamica utilizării terenului. Vegetația uscată crește puternic în sud, sugerând posibile efecte ale gestionării hidrologice și ale schimbărilor climatice, în timp ce clasa apă prezintă atât contracții, cât și expansiuni locale. Figura 10 prezintă suma totală a schimbărilor, iar Figura 11 sintetizează fluxurile de tranziție între clase, evidențiind faptul că fluxul dominant este vegetație naturală către vegetație naturală, reflectând stabilitatea ecosistemului, în timp ce tranzițiile vegetație naturală către vegetație uscată și vegetație naturală în ambele sensuri cu terenuri agricole sunt fluxuri semnificative, indicând presiuni combinate antropice și naturale asupra Deltei Dunării.

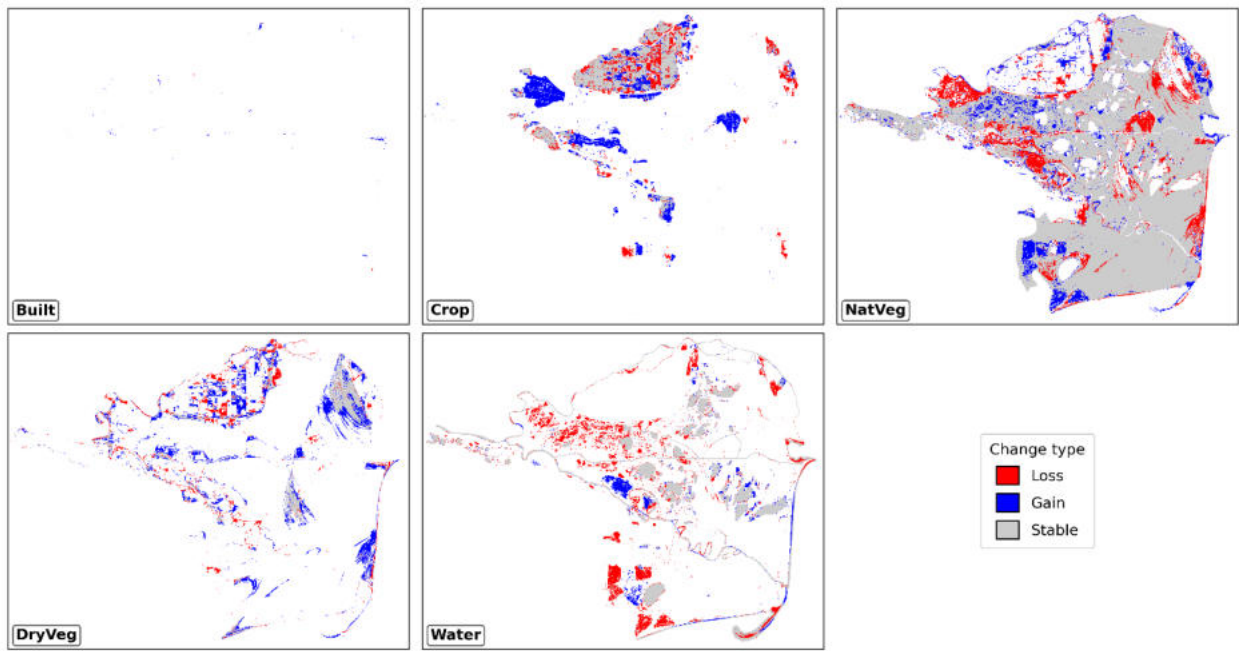


Figura 9. Tipuri de modificări 1985-2025.

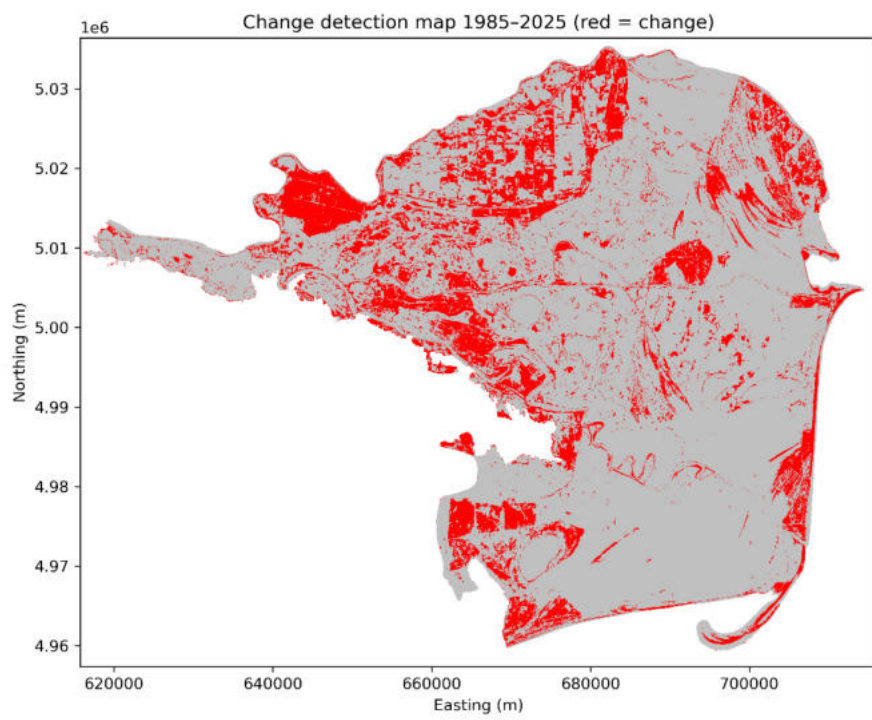


Figura 10. Schimbările totale.




Figura 11. Tranziția claselor.

4. Analiza distribuției spațiale a zonelor umede

Studiul prezent utilizează arhiva completă Sentinel-1 Ground Range Detected (GRD) pentru perioada 2015–2024, procesată prin cadrul Advanced Radiometric Terrain-Corrected (ARD) dezvoltat în Google Earth Engine. Procesarea include corecția zgomotului de margine, filtrare speckle de intensitate redusă de tip Gamma-MAP, normalizare radiometrică la γ_0 și conversie în decibeli. Pe baza colecției armonizate Sentinel-1 ARD au fost generate statistici temporale robuste, precum mediana VV și percentila 10 (p10), aceste două produse fundamentale fiind utilizate ulterior pentru derivarea pragurilor optime de clasificare apă–uscat. Determinarea pragurilor a fost realizată printr-o abordare calibrată, folosind date de referință independente provenite din harta de occurrence JRC Global Surface Water, ceea ce a permis izolarea a două seturi de pixeli de „apă permanentă” și „uscat permanent”. Ulterior, au fost aplicate trei metode statistice – Otsu, Youden J și Minimum Classification Error – asupra histogramelor VV construite pe baza regulii Freedman–Diaconis pentru determinarea lățimii barelor. În ambele situații analizate (median și p10), criteriul Youden J a oferit cel mai stabil și mai consistent prag de separare, identificând valorile $-15,74$ dB pentru mediană și $-19,33$ dB pentru p10. Aceste praguri au stat la baza producerii unei hărți robuste de occurrence a apei, printr-o regulă condițională care păstrează sensibilitate ridicată în zonele acvatice și un caracter conservator pe suprafețele terestre.

4.1 Metodologie

4.1.1 Preprocesarea datelor Sentinel-1 în cadrul ARD

Pentru generarea unei serii multitemporale coerente de imagini radar, întreaga arhivă Sentinel-1 GRD pentru perioada 2015–2024 a fost procesată utilizând cadrul Sentinel-1 ARD (Analysis-Ready Data) implementat în Google Earth Engine. Preprocesarea a urmat metodologia standardizată propusă în literatura de specialitate și a inclus selecția datelor pentru intervalul 01.01.2015–01.01.2025, utilizând polarizarea VV și atât orbite ascendente, cât și descendente, pentru zona de interes constituită din Delta Dunării și zona costieră adiacentă. A fost aplicată corecția zgomotului de margine, pentru eliminarea artefactelor specifice modului IW Sentinel-1 prezente la marginile swath-urilor radar și pentru asigurarea unei radiometrie stabile pe întreaga imagine.

Filtrarea speckle a fost realizată cu un filtru Gamma-MAP, într-un cadru mono-temporal, utilizând un nucleu de 7×7 pixeli, pentru a reduce variația internă a corpurilor de apă fără a altera geometriile fine sau limitele uscat–apă. Normalizarea radiometrică la γ_0 , cu corecție de teren, a fost realizată pentru fiecare scenă folosind modelul digital de teren SRTM (30 m), cu un model de flattening de tip VOLUME și conversia valorilor de retrodifuzie din putere liniară în decibeli. După aceste etape, imaginile au fost decupate pe zona de interes, reproiectate pe aceeași grilă spațială de 10 m și reduse la banda VV exprimată în decibeli (VV_dB), păstrându-se proprietățile temporale pentru analize ulterioare.

4.1.2 Generarea statisticilor temporale VV median și VV p10

Pentru caracterizarea distribuției multitemporale a retrodifuziei radar și fundamentarea detecției stabile a apei au fost generate două produse statistice principale. Mediana VV (VV_med) reduce influența valorilor extreme și a zgomotului rezidual și oferă o reprezentare robustă a comportamentului tipic al suprafeței. Percentila 10 (VV_p10) surprinde situațiile cu cea mai mică retrodifuzie în intervalul analizat, reflectând episoadele în care apa este cel mai clar identificabilă din punct de vedere radar. Valorile p10 sunt esențiale pentru detecția apei persistente și pentru separarea clară a claselor apă–uscat în condiții favorabile de observație.

4.1.3 Exportul rasterelor finale

Produsele statistice finale au fost exportate din Google Earth Engine sub forma a două fișiere GeoTIFF la rezoluția de 10 m, anume S1_ARD_VV_med_2015_2024_lightSpeckle.tif și S1_ARD_VV_p10_2015_2024_lightSpeckle.tif. Aceste fișiere constituie intrările principale pentru etapele ulterioare de analiză realizate în Python.

4.1.4 Derivarea pragurilor optimizate de clasificare în Python

Pentru determinarea pragurilor optime de separare apă–uscat, rasterele VV_p10 și VV_med au fost analizate împreună cu datele de referință hidrologică din produsul JRC Global Surface Water – Occurrence, reprojecat la 10 m. Au fost izolate două subseturi curate (Figura 12), corespunzătoare pixelilor cu occurrence egal cu 0 % (LAND, pământ permanent) și pixelilor cu occurrence de cel puțin 95 % (WATER, apă permanentă).




Figura 12. JRC apă permanentă/pământ permanent.

Pentru a descrie corespunzător distribuțiile valorilor de retrodifuzie radar pentru apă și uscat, histogramelor VV li s-a stabilit lățimea barelor pe baza regulii Freedman–Diaconis, prin formula $h = (2 \times \text{IQR}) / n^{1/3}$, evitând atât supra-agregarea, cât și fragmentarea excesivă a datelor. Pe aceste histograme au fost aplicate trei metode de determinare a pragului: metoda Otsu, care maximizează varianța inter-clase; metoda Youden J, care optimizează simultan sensibilitatea și specificitatea, prin $J = \text{TPR} + \text{TNR} - 1$; și metoda Minimum Classification Error (MCE), care minimizează suma erorilor de tip fals pozitiv și fals negativ. Pentru VV median au rezultat pragurile $-15,49$ dB (Otsu), $-15,74$ dB (Youden J) și $-15,09$ dB (MCE), iar pentru VV p10, pragurile $-19,28$ dB (Otsu), $-19,33$ dB (Youden J) și $-18,74$ dB (MCE).

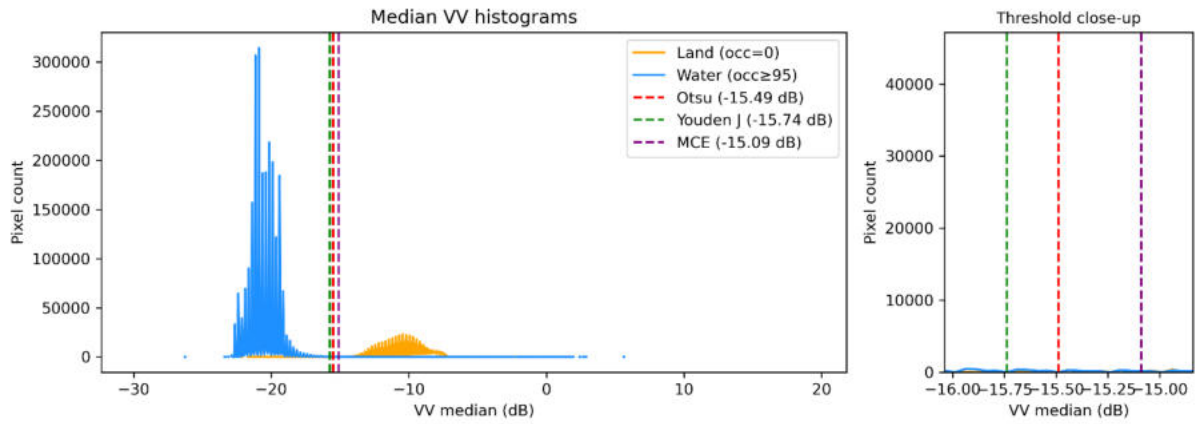


Figura 13. Histogramă VV median.

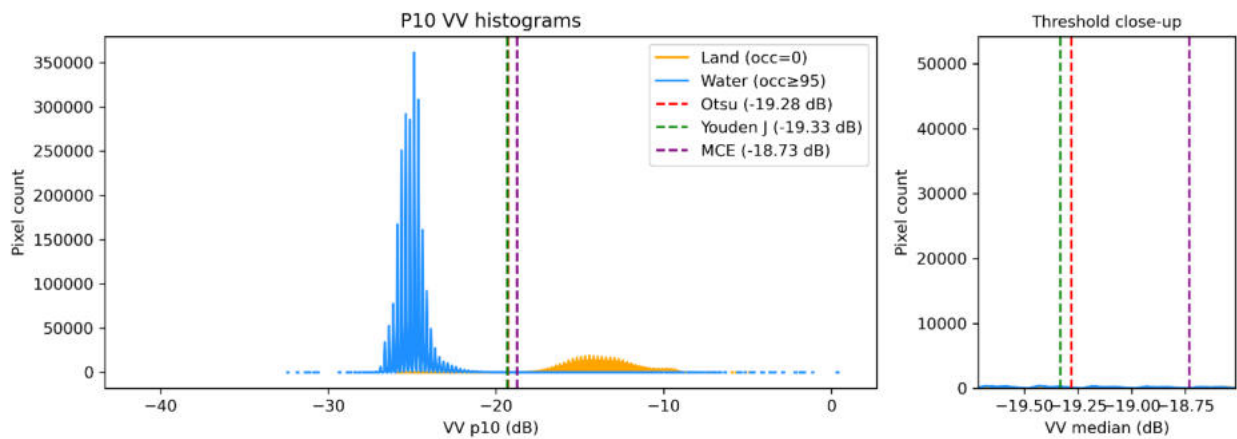


Figura 14. Histogramă p10.

4.1.5 Criterii de selecție a pragurilor finale

fost realizată pe baza mai multor criterii. În primul rând, s-a urmărit echilibrul între clase, exprimat prin Balanced Accuracy și prin raportul dintre sensibilitate (TPR) și specificitate (TNR). Metoda Youden J a produs valori aproape simetrice pentru TPR și TNR și a condus la cele mai ridicate valori ale TNR, indicând o protecție mai bună împotriva clasificării false a uscatului ca apă. În al doilea rând, s-a ținut cont de dezechilibrul claselor în setul de referință, care conține mult mai mulți pixeli de apă decât de uscat; în acest context, metricile bazate doar pe acuratețe globală pot favoriza clasificatoarele care tind să atribuie clasa dominantă, iar MCE are tendința de a produce praguri prea permissive, crescând rata de fals pozitivi. În al treilea rând, s-a evaluat stabilitatea pragurilor în raport cu distribuțiile histogramelor,

observându-se că pragurile Youden J coincid cu zona de minim („vale”) dintre modurile distribuțiilor, în ciuda variabilității acestora.

Pentru VV median, pragul de $-15,74$ dB furnizat de Youden J este ușor mai conservator decât pragul MCE, dar oferă cel mai bun compromis între TPR și TNR și cea mai ridicată valoare a indicatorului J, fiind astfel considerat optim. Pentru VV p10, pragul $-19,33$ dB obținut prin Youden J păstrează aceleași caracteristici de echilibru, în timp ce MCE tinde din nou către un prag prea permisiv, iar Otsu identifică un prag stabil, dar ușor deplasat față de separarea ideală a claselor. Prin urmare, pragurile finale utilizate în analiză au fost $-15,74$ dB pentru VV median și $-19,33$ dB pentru VV p10.

Generarea hărții finale de water occurrence prin combinarea pragurilor VV_med și VV_p10

Cele două praguri selectate, $-15,74$ dB pentru VV median și $-19,33$ dB pentru VV p10, oferă niveluri diferite de sensibilitate și robustețe în discriminarea apei (Figura 15), ceea ce a impus o strategie de combinare complementară pentru obținerea unei hărți unice de water occurrence. Obiectivul a fost obținerea unei reprezentări spațiale coerente, stabilă pe suprafețele acvatice și conservatoare pe zonele terestre, evitând artefactele induse de zgomot, vegetație sau suprafețe întunecate care pot fi confundate cu apa.

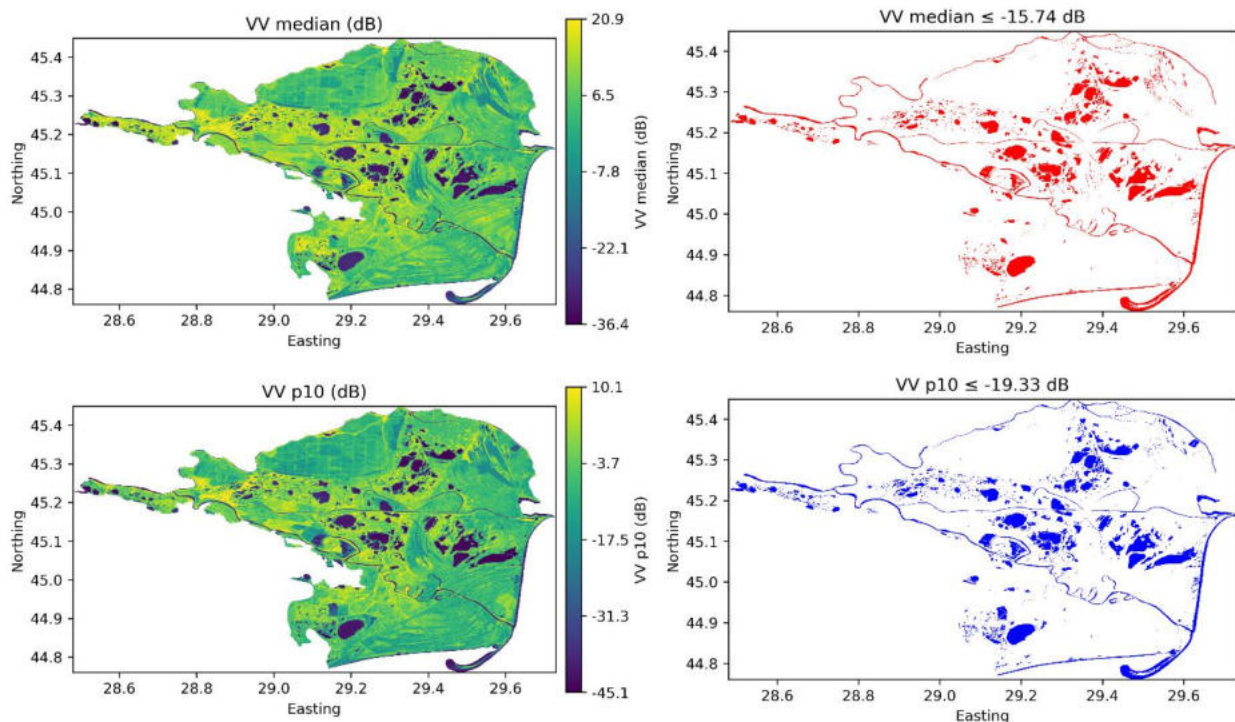


Figura 15. VV median/VV p10

În prima etapă a fost construită o mască de apă cu încredere ridicată, folosind percentila 10. Percentila 10 reflectă situațiile cu cea mai mică retrodifuzie pentru fiecare pixel în intervalul analizat, reprezentând momentele în care apa este cel mai clar identificabilă. Pragul $-19,33$ dB derivat prin criteriul Youden J a fost utilizat pentru generarea unei măști binare în care valoarea 1 marchează apă persistentă sau apă cu detecție foarte sigură, iar valoarea 0 indică uscat sau zone neincluse în categoria de apă sigură. Această mască identifică exclusiv pixelii cu comportament hidrologic consistent cu apa în cele mai favorabile momente radar, reducând riscul de fals pozitive.

În etapa următoare, din rasterele Sentinel-1 au fost generate două hărți de occurrence, una bazată pe pragul mediei (Occurrence_med, la $-15,74$ dB), mai sensibilă și capabilă să surprindă dinamica internă a suprafețelor acvatice, inclusiv extinderi subtile sau zone temporar inundate, și una bazată pe pragul p10 (Occurrence_p10, la $-19,33$ dB), mai conservatoare, menită să evite clasificarea eronată a vegetației dense, a solurilor umede sau a umbrelor radar drept apă și adecvată pentru delimitarea sigură a zonelor non-acvatice.

În ultima etapă, occurrence-ul final a fost determinat printr-o regulă decizională pixel cu pixel. Pentru toți pixelii pentru care masca de apă derivată din p10 este egală cu 1 a fost utilizat Occurrence_med, asigurând o sensibilitate ridicată și descrierea detaliată a variabilității hidrologice în interiorul corpurilor de apă. Pentru pixelii cu mască de apă egală cu 0 a fost utilizat Occurrence_p10, reducând astfel fals pozitivele pe uscat și pe suprafețele non-acvatice. Pixelii invalizi, fie marcați ca nodata, fie situați în afara ariei de interes, au fost păstrați ca nodata, menținând consistența rasterului final.

Această abordare condițională exploatează avantajele fiecărei hărți de occurrence. Utilizarea occurrence-ului mai sensibil în interiorul corpurilor de apă permite captarea fluctuațiilor hidrologice reale, detectarea canalelor mici, a bălților interne și a zonelor inundabile, oferind o reprezentare realistă a dinamicii interne a Deltei Dunării. În același timp, utilizarea occurrence-ului conservator pe uscat previne clasificarea vegetației drept apă, filtrează solurile umede cu backscatter redus și reduce efectele umbririi radar interpretate greșit ca apă, fiind robustă inclusiv în zone antropizate sau cu backscatter atipic.

4.2 Harta finală de water occurrence pentru perioada 2015–2024

Produsul central al proiectului este harta multitemporală de water occurrence, generată prin combinarea condițională a pragurilor $-15,74$ dB (mediana VV) și $-19,33$ dB (p10). Rezultatul este o hartă continuă a probabilității de apariție a apei în intervalul 2015–2024 (Figure 16), care arată distribuția spațială a zonelor acvatice și diferențiază între lacurile permanente, canalele și bălțile intermitente și zonele rar inundate.

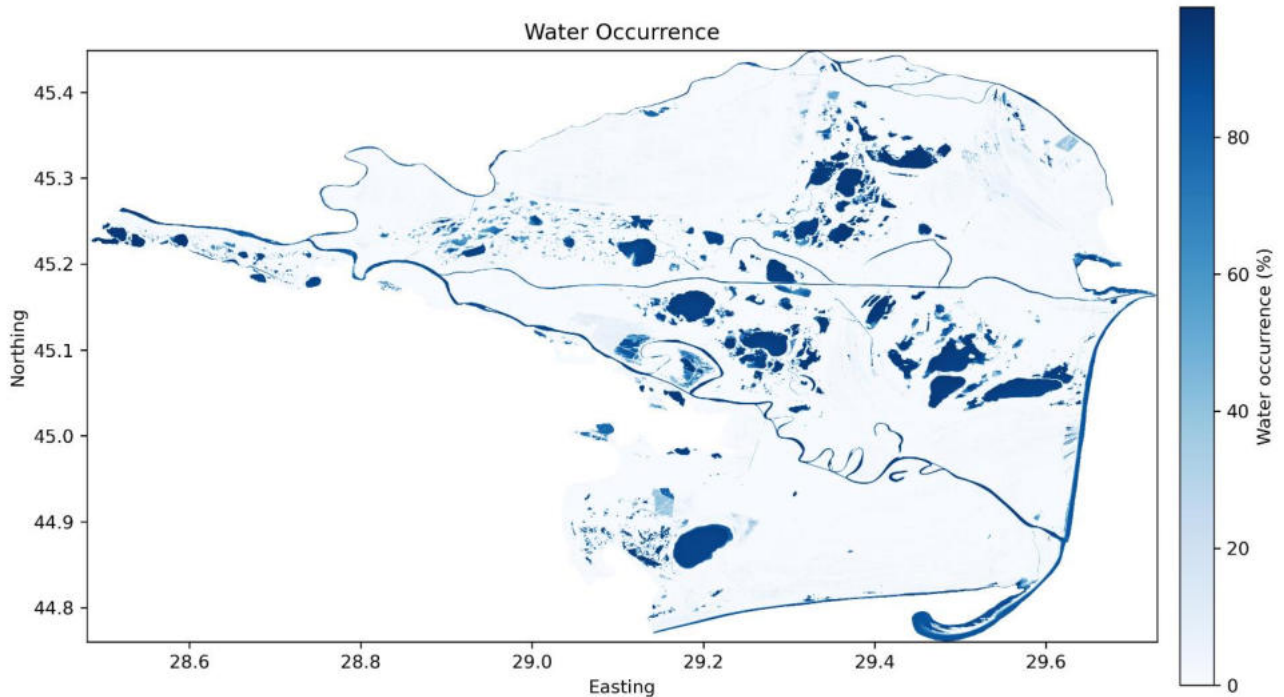


Figure 16. Hartă de prezență a apei.

Harta evidențiază lacurile permanente cu occurrence mai mare de 80 %, canalele și bălțile intermitente cu occurrence cuprins între 20 % și 80 % și zonele rar inundate, cu occurrence sub 20 %, asociate de regulă stufului, solurilor umede sau zonelor cu nivel freatic ridicat.

Distribuția suprafeței acvatice pe clase de occurrence

Pentru a evalua stabilitatea hidrologică a Deltei Dunării a fost calculată suprafața, exprimată în hectare, aferentă fiecărei clase de occurrence (Figure 17). Rezultatele arată că cea mai mare parte a suprafeței, aproximativ 78.000 ha, are occurrence între 1 % și 10 %, indicând zone ocazional inundate, asociate cu stuf, soluri umede sau zone cu pânză freatică ridicată. Aproximativ 27.000 ha reprezintă apă stabilă, cu occurrence mai mare de 90 %, delimitând lacurile majore precum Roșuleț, Roșu, Lumina, Puiu și altele. Această distribuție evidențiază caracterul puternic variabil și sezonier al zonei.




Figure 17. Distribuția suprafeței acoperite de apă pe clase de occurrence.

4.3 Extinderea totală a apei în perioada 2015–2024

Pentru a evalua suprafața maximă potențială ocupată de apă a fost generată o hartă binară a pixelilor care au fost clasificați ca apă în cel puțin o scenă Sentinel-1 din perioada analizată. Această hartă de extindere totală a apei (Figure 18) evidențiază zonele predispuse la inundații temporare, culoarele dinamice ale canalelor și suprafețele afectate de variații sezoniere majore.




Figure 18. Extinderea totală a apei în intervalul 2015–2024.

4.4 Clasificarea stabilității hidrologice

Pe baza valorilor de water occurrence au fost definite patru clase hidrologice interpretative: 0 % – uscat sau fără apă, 1–19 % – apă cu prezență rară, 20–80 % – apă intermitentă și peste 80 % – apă stabilă. Harta claselor de stabilitate hidrologică (Figura 18) arată că Delta Dunării prezintă un nucleu clar de lacuri permanente, cu occurrence ridicat, înconjurat de un halou extins de zone intermitent inundate și de o matrice vastă de zone slab inundabile. Această structură spațială reflectă conectivitatea hidrologică complexă a sistemului deltaic și evidențiază zonele cheie pentru managementul apei și pentru conservarea ecosistemelor.

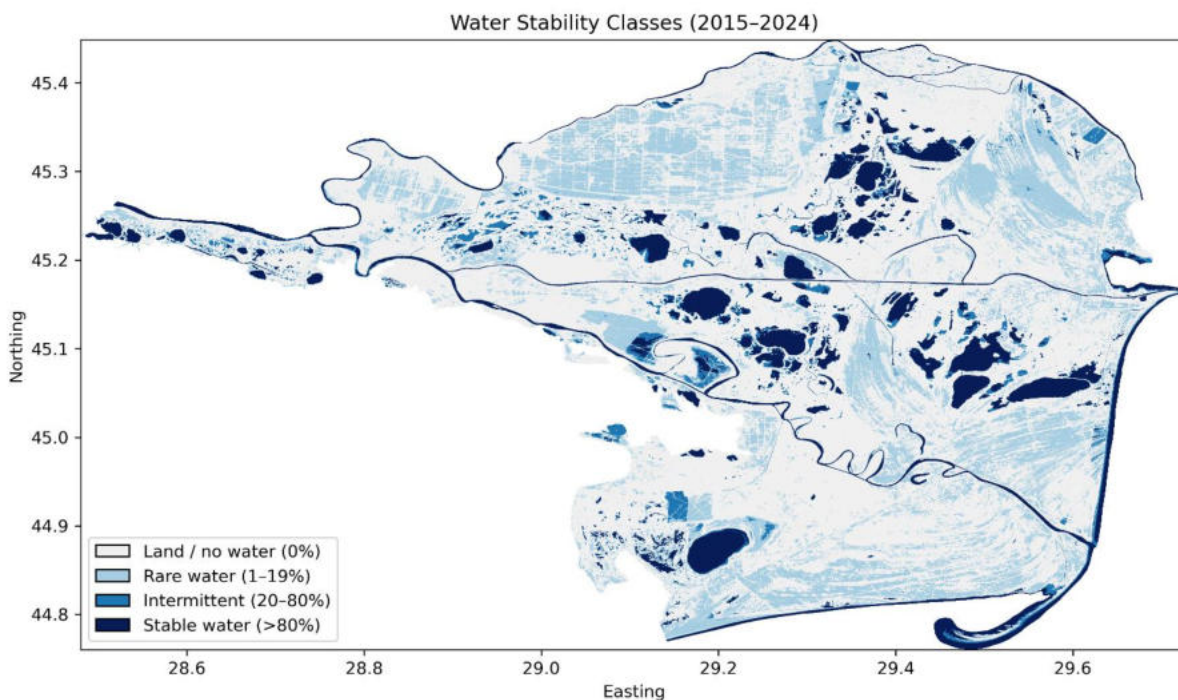


Figure 19. Clase de stabilitate a apei în perioada 2015–2024.

Diseminare

Conform propunerii de proiect, rezultatele obținute vor fi publicate în 3 jurnale științifice. Menționăm că gradul de îndeplinire a acestei cerințe este următorul:

- 1 articol BDI (legat de metodologia de evaluarea a acoperirii terenurilor) este finalizat în proporție de 90%, urmând a fi publicat în luna decembrie a.c.,
- 1 articol ISI (legat de distribuția spațiilor umede) este finalizat în proporție de 90%, urmând a fi publicat în luna decembrie a.c.,
- 1 articol ISI (legat de eutrofizarea din Delta Dunării prin modelarea parametrului clorofila) este finalizat în proporție de 50%, urmând a fi publicat în luna februarie 2026.

Referințe

- Ali, A., Zhou, G., Pablo Antezana Lopez, F., Xu, C., Jing, G., & Tan, Y. (2024). Deep learning for water quality multivariate assessment in inland water across China. *International Journal of Applied Earth Observation and Geoinformation*, *133*, 104078. <https://doi.org/10.1016/j.jag.2024.104078>
- Atton Beckmann, D., Spyrakos, E., Hunter, P., & Jones, I. D. (2025). Widespread phytoplankton monitoring in small lakes: A case study comparing satellite imagery from planet SuperDoves and ESA sentinel-2. *Frontiers in Remote Sensing*, *6*, 1549119. <https://doi.org/10.3389/frsen.2025.1549119>
- Cao, Z., Ma, R., Melack, J. M., Duan, H., Liu, M., Kutser, T., Xue, K., Shen, M., Qi, T., & Yuan, H. (2022). Landsat observations of chlorophyll-a variations in Lake Taihu from 1984 to 2019. *International Journal of Applied Earth Observation and Geoinformation*, *106*, 102642. <https://doi.org/10.1016/j.jag.2021.102642>
- Deng, Y., Zhang, Y., Pan, D., Yang, S. X., & Gharabaghi, B. (2024). Review of Recent Advances in Remote Sensing and Machine Learning Methods for Lake Water Quality Management. *Remote Sensing*, *16*(22), 4196. <https://doi.org/10.3390/rs16224196>
- Ecosystems and water quality*. (2023, March 21). <https://www.unep.org/interactives/wwqa/technical-highlights/ecosystems-and-water-quality>
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, *202*, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Guan, Q., Feng, L., Hou, X., Schurgers, G., Zheng, Y., & Tang, J. (2020). Eutrophication changes in fifty large lakes on the Yangtze Plain of China derived from MERIS and OLCI observations. *Remote Sensing of Environment*, *246*, 111890. <https://doi.org/10.1016/j.rse.2020.111890>

- Liu, D., Duan, H., Loisel, S., Hu, C., Zhang, G., Li, J., Yang, H., Thompson, J. R., Cao, Z., Shen, M., Ma, R., Zhang, M., & Han, W. (2020). Observations of water transparency in China's lakes from space. *International Journal of Applied Earth Observation and Geoinformation*, 92, 102187. <https://doi.org/10.1016/j.jag.2020.102187>
- Llodrà-Llabrés, J., Martínez-López, J., Postma, T., Pérez-Martínez, C., & Alcaraz-Segura, D. (2023). Retrieving water chlorophyll-a concentration in inland waters from Sentinel-2 imagery: Review of operability, performance and ways forward. *International Journal of Applied Earth Observation and Geoinformation*, 125, 103605. <https://doi.org/10.1016/j.jag.2023.103605>
- Poddar, S., Chacko, N., & Swain, D. (2019). Estimation of Chlorophyll-a in Northern Coastal Bay of Bengal Using Landsat-8 OLI and Sentinel-2 MSI Sensors. *Frontiers in Marine Science*, 6, 598. <https://doi.org/10.3389/fmars.2019.00598>
- THE 17 GOALS | *Sustainable Development*. (n.d.). Retrieved June 29, 2025, from <https://sdgs.un.org/goals>
- Transforming our world: The 2030 Agenda for Sustainable Development* | Department of Economic and Social Affairs. (n.d.). Retrieved June 29, 2025, from <https://sdgs.un.org/2030agenda>
- Xia, R., Zhang, Y., Critto, A., Wu, J., Fan, J., Zheng, Z., & Zhang, Y. (2016). The Potential Impacts of Climate Change Factors on Freshwater Eutrophication: Implications for Research and Countermeasures of Water Management in China. *Sustainability*, 8(3), 229. <https://doi.org/10.3390/su8030229>
- Zhang, D., Shi, K., Wang, W., Wang, X., Zhang, Y., Qin, B., Zhu, M., Dong, B., & Zhang, Y. (2024). An optical mechanism-based deep learning approach for deriving water trophic state of China's lakes from Landsat images. *Water Research*, 252, 121181. <https://doi.org/10.1016/j.watres.2024.121181>

