

UNIVERSITATEA DIN BUCUREȘTI

Facultatea de Geografie

LUCRARE DE DISERTAȚIE

Îndrumător științific:

Conf. Univ. Dr. Ștefan Constantinescu

Absolvent:

Gabriel Dan Boerencu

BUCUREȘTI

2015

UNIVERSITATEA DIN BUCUREȘTI

Facultatea de Geografie

Program de studii: Master Sisteme Informationale Geografice

**MONITORIZAREA SPECIILOR DE VEGETAȚIE ACVATICĂ
SUBMERSĂ DIN DELTA DUNĂRII PRIN MIJLOACE DE
TELEDETECȚIE**

Îndrumător științific:

Conf. Univ. Dr. Ștefan Constantinescu

Absolvent:

Gabriel Dan Boerencu

BUCUREȘTI

2015

CUPRINS

LISTA FIGURILOR

LISTA TABELELOR

LISTA FOTOGRAFIILOR

LISTA ACRONIMELOR ȘI ABREVIERILOR

MOTIVAȚIE	14
CAPITOLUL 1 - ISTORICUL CERCETĂRII	15
1.1 Lucrări pe plan internațional.....	15
1.2 Lucrări pe plan național	18
CAPITOLUL 2 - TEHNICA DE LUCRU ȘI METODOLOGIA	20
2.1 Delta Dunării - caracteristici generale	20
2.2 Vegetația acvatică	21
2.3 Teledetecție aplicată pentru determinarea speciilor de plante acvatice submerse.....	23
2.4 Aria de studiu	24
2.4.1 Date din teren	25
2.5 Imagini de teledetecție folosite	27
2.5.1 Achiziționarea imaginilor	27
2.5.2 Procesarea imaginilor	28
2.5.2.1 Pre-procesarea imaginilor.....	29
2.5.2.2 Procesarea componentelor principale si definirea zonelor de interes	31
2.5.2.3 Clasificarea imaginilor	32
2.5.3 Post-clasificarea imaginilor	34
CAPITOLUL 3 - REZULTATE ȘI DISCUȚII	35
3.1 Caracteristici ale comunităților de vegetație acvatică submersă determinate în teren.....	35
3.2 Pre-procesarea imaginilor Landsat 7	37
3.2.1 Umplerea golurilor, crearea mozaicului și tăierea imaginii.....	37
3.2.2 Analiza componentelor principale	42
3.2.3 Clasificarea imaginilor	44
3.2.3.1 Definirea zonelor de interes	44
3.2.3.2 Analiza separabilității.....	46
3.2.3.3 Evaluarea metodelor de clasificare supervizată	48
3.3 Pre-procesarea imaginilor Landsat 8	53
3.3.1 Crearea mozaicului și tăierea imaginii	53

3.3.2 Analiza componentelor principale	56
3.3.3 Clasificarea imaginilor	58
3.3.3.1 Definirea zonelor de interes	58
3.3.3.2 Analiza separabilității.....	59
3.3.3.3 Evaluarea metodelor de clasificare supervizată	60
3.4 Comparatie între rezultatele obținute în urma proesării celor două imagini	67
CAPITOLUL 4 - CONCLUZII	70
BIBLIOGRAFIE	73
Anexa 1 - Specii de vegetație acvatică submersă observate în aria de studiu	78
Anexa 2 - Date statistice obținute în urma proceselor de clasificare	82

LISTA FIGURILOR

2.1 Variația reflectanței vegetației acvatice submerse în funcție de adâncime. Graficul este valabil pentru apa limpede, cu adâncimi între 10 și 50 cm.....	24
2.2 Aria de studiu	25
2.3 Aria de studiu în teren	26
2.4 Etape de lucru	28
2.5 Imaginea zonei de nord a pădurii Letea în tonuri de gri pentru benzile albastru, verde, respectiv roșu, de la stânga spre dreapta, și reprezentarea RGB	31
2.6 Imaginea zonei de nord a pădurii Letea în tonuri de gri pentru componentele principale unu, doi, trei și patru, în această ordine, de la stânga spre dreapta	31
3.1 Delta Dunării - imagine Landsat 7 tăiată conform limitelor stabilite	38
3.2 NDWI - transect în zona de sud a ariei de de studiu; sensul transectului: de la dreapta spre stânga	40
3.3 NDWI - transect în zona de nord-vest a ariei de studiu; se observă înregistrarea GPS a traseului parcurs în caiac	40
3.4 MNDWI - transect în zona de sud a ariei de de studiu; sensul transectului: de la dreapta spre stânga	41
3.5 MNDWI - transect în zona de nord-vest a ariei de studiu; se observă înregistrarea GPS a traseului parcurs în caiac	41
3.6 Valorile Eigen rezultate în urma analizei componentelor principale pentru imaginea Landsat 7	42
3.7 Valorile minime, maxime (roșu), medii (alb), deviațiile standard (verde) pentru componentele principale pentru imaginea Landsat 7	42

3.8 Componenta principală numărul patru afișată în tonuri de gri.....	43
3.9 Clasificarea nesupervizată ISODATA pentru purificarea zonelor de interes: stânga - înainte de combinarea claselor, dreapta - cele 4 clase finale.....	44
3.10 Zone de interes definite: albastru - apă limpede, galben - apă cu turbiditate ridicată, verde deschis - vegetație acvatică submersă, brun - sol și dune, verde închis - vegetație, albastru deschis - nori	45
3.11 Valori medii ale zonelor de interes în funcție de bandă.....	46
3.12 Deviații standard ale zonelor de interes în funcție de bandă.....	47
3.13 Suprafețe ocupate de clasele obținute prin diferite metode de clasificare	48
3.14 Clasificare prin metoda distanței minime (Minimum Distance).....	49
3.15 Clasificare prin metoda unghiului spectral (Spectral Angle Mapper).....	50
3.16 Clasificare prin metoda rețelelor neuronale artificiale	51
3.17 Delta Dunării - imagine Landsat 8 tăiata conform limitelor stabilite	54
3.18 Reprezentare a unei zone acoperite de nori în combinație RGB (stânga) și în reprezentare în tonuri de gri pentru indicii I_1 (dreapta).....	55
3.19 Valorile Eigen rezultate în urma analizei componentelor principale pentru imaginea Landsat 8	57
3.20 Valorile minime, maxime (rosu), medii (alb), deviațiile standard (verde) pentru componentele principale pentru imaginea Landsat 8.....	57
3.21 Valori medii ale zonelor de interes în funcție de bandă pentru imaginea Landsat 8	59
3.22 Deviații standard ale zonelor de interes în funcție de bandă pentru imaginea Landsat 8	59
3.23 Clasificare prin metoda paralelipiped	61
3.24 Clasificare prin metoda distanței minime.....	62
3.25 Clasificare prin metoda probabilității maxime	63

3.26 Clasificare prin metoda unghiului spectral	64
3.27 Clasificare prin metoda rețelelor neuronale artificiale	65
3.28 Suprafețele ocupate de fiecare clasă pentru metodele de clasificare utilizate	66
3.29 Preciziile de estimare și de interpretare corespunzătoare clasei vegetație acvatică submersă pentru diverse metode de clasificare	68

LISTA TABELELOR

2.1 Lista benzilor senzorului Landsat 8	30
3.1 Specii identificate în teren	35
3.2 Date statistice rezultate în urma analizei componentelor principale pentru imaginea Landsat 7	43
3.3 Acuratețea globală și coeficientul kappa pentru metodele de clasificare utilizate ..	52
3.4 Matricea de confuzie pentru clasificarea prin metoda distanței minime	52
3.5 Date statistice rezultate în urma analizei componentelor principale pentru imaginea Landsat 8	58
3.6 Acuratețea globală și coeficientul kappa pentru metodele de clasificare utilizate pentru imaginea Landsat 8	66
A.2.1 Suprafețele ocupate de diverse clase - imaginea Landsat 7 (km ²).....	82
A.2.2 Suprafețele ocupate de diverse clase - imaginea Landsat 8 (km ²).....	82
A.2.3 Matricea de confuzie pentru clasificarea prin metoda distanței minime - imaginea Landsat 7 (%).....	83
A.2.4 Matricea de confuzie pentru clasificarea prin metoda rețelelor neuronale artificiale - imaginea Landsat 7 (%).....	83
A.2.5 Matricea de confuzie pentru clasificarea prin metoda unghiului spectral - imaginea Landsat 7 (%)	84
A.2.6 Matricea de confuzie pentru clasificarea prin metoda paralelipiped - imaginea Landsat 8 (%).....	84
A.2.7 Matricea de confuzie pentru clasificarea prin metoda distanței minime - imaginea Landsat 8 (%).....	85

A.2.8 Matricea de confuzie pentru clasificarea prin metoda probabilității maxime - imaginea Landsat 8 (%)	85
A.2.9 Matricea de confuzie pentru clasificarea prin metoda unghiului spectral - imaginea Landsat 8 (%)	86
A.2.10 Matricea de confuzie pentru clasificarea prin metoda rețelelor neuronale artificiale - imaginea Landsat 8 (%).....	86
A.2.11 Precizia de estimare si de interpretare pentru rezultatele clasificarii prin metoda distanței minime - imaginea Landsat 7	87
A.2.12 Precizia de estimare si de interpretare pentru rezultatele clasificarii prin metoda unghiului spectral - imaginea Landsat 7.....	87
A.2.13 Precizia de estimare si de interpretare pentru rezultatele clasificarii prin metoda rețelelor neuronale artificiale - imaginea Landsat 7	88
A.2.14 Precizia de estimare si de interpretare pentru rezultatele clasificarii prin metoda paralelipiped - imaginea Landsat 8	88
A.2.15 Precizia de estimare si de interpretare pentru rezultatele clasificarii prin metoda distanței minime - imaginea Landsat 8	89
A.2.16 Precizia de estimare si de interpretare pentru rezultatele clasificarii prin metoda probabilității maxime - imaginea Landsat 8.....	89
A.2.17 Precizia de estimare si de interpretare pentru rezultatele clasificarii prin metoda unghiului spectral - imaginea Landsat 8.....	90
A.2.18 Precizia de estimare si de interpretare pentru rezultatele clasificarii prin metoda rețelelor neuronale artificiale - imaginea Landsat 8	90
A.2.19 Erorile de includere si de omisiune pentru rezultatele clasificarii prin metoda distanței minime - imaginea Landsat 7	91
A.2.20 Erorile de includere si de omisiune pentru rezultatele clasificarii prin metoda unghiului spectral - imaginea Landsat 7	91
A.2.21 Erorile de includere si de omisiune pentru rezultatele clasificarii prin metoda rețelelor neuronale artificiale - imaginea Landsat 7.....	92
A.2.22 Erorile de includere si de omisiune pentru rezultatele clasificarii prin metoda paralelipiped - imaginea Landsat 8.....	92

A.2.23 Erorile de includere si de omisiune pentru rezultatele clasificarii prin metoda distanței minime - imaginea Landsat 8.....	93
A.2.24 Erorile de includere si de omisiune pentru rezultatele clasificarii prin metoda probabilității maxime - imaginea Landsat 8	93
A.2.25 Erorile de includere si de omisiune pentru rezultatele clasificarii prin metoda unghiului spectral - imaginea Landsat 8	94
A.2.26 Erorile de includere si de omisiune pentru rezultatele clasificarii prin metoda rețelelor neuronale artificiale - imaginea Landsat 8.....	94

LISTA FOTOGRAFIILOR

2.1 Comunitate de <i>Potamogeton crispus</i> la marginea canalului Uzlina	23
2.2 Vegetație acvatică submersă pe lacul Uzlina și un pelican în plan îndepărtat	26
2.3 Locul de campare la marginea lacului Isaac	27
3.1 Nuphar luteum și <i>Potamogeton pectinatus</i>	36
3.2 <i>Trapa natans</i> și <i>Potamogeton pectinatus</i>	37
A.1 <i>Potamogeton pectinatus</i> și <i>Trapa natans</i>	78
A.2 <i>Potamogeton crispus</i>	79
A.3 Nuphar luteum	80
A.4 <i>Nymphaea alba</i>	81

LISTA ACRONIMELOR ȘI ABREVIERILOR

AVIRIS - Airborne visible/infrared imaging spectrometer

AVHRR - Advanced Very High Resolution Radiometer

ETM+ - Enhanced Thematic Mapper Plus

GPS - Global Positioning Sistem

LIDAR - Light Detection and Ranging

MIR - Mid-Infrared

MNDWI - Modified Normalized Difference Water Index

MODIS - Moderate-Resolution Imaging Spectroradiometer

NASA - National Aeronautics and Space Administration

NDWI - Normalized Difference Water Index

NIR - Near-Infrared

NOAA - National Oceanic and Atmospheric Administration

RGB - Red, Green, Blue

SPOT - Satellite Pour l'Observation de la Terre

SVI - Simple Vegetation Index

UTM - Universal Transverse Mercator

WGS - World Geodetic System

MOTIVAȚIE

Sistemele ecologice din zonele umede ocupă un rol important în ciclurile biogeochimice globale sau regionale și constituie sursă, zonă de depozitare și de transformare pentru diferite materiale organice și anorganice. Fluxurile de nutrienți, de sedimente și substanțe rezultate în urma activităților umane, transportate de sistemele acvatice sunt absorbite și procesate în zonele umede. În plus, aceste zone influențează ciclurile hidrologice și se constituie în habitat pentru o mare diversitate de specii de plante și animale.

Delta Dunării este una dintre cele mai importante zone umede din Europa. Dinamica acestui ecosistem este influențată de variațiile sezoniere ale nivelului apei. Vegetația acvatică și de mlaștină reprezintă aproximativ 70% din unitățile de vegetație existente în deltă (Hanganu et. al, 2002) și ocupă un rol important în cadrul acestui sistem ecologic acționând ca filtru pentru nutrienții și sedimentele care ajung în această zonă.

Datorită suprafeței considerabile a deltei și a accesibilității reduse a anumitor zone mijloacele de teledetecție constituie un instrument important pentru studierea dinamicii vegetației acvatice submerse și flotante.

Această lucrare își propune să evalueze aplicabilitatea utilizării metodelor de procesare digitală a imaginilor Landsat pentru evaluarea suprafețelor acoperite de vegetație acvatică și este organizată în patru capitole:

- Capitolul 1 - Istoricul cercetării
- Capitolul 2 - Tehnica de lucru și metodologia
- Capitolul 3 - Rezultate și discuții
- Capitolul 4 - Concluzii

CAPITOLUL 1

ISTORICUL CERCETĂRII

1.1 Lucrări pe plan internațional

Evaluarea și monitorizarea stării suprafeței pământului este o cerință cheie pentru cercetarea schimbărilor globale (Jung et al. 2006; Lambin et al. 2001). Clasificarea și cartografierea vegetației reprezintă o sarcină tehnică importantă pentru managementul resurselor naturale, deoarece vegetația oferă un mediu propice dezvoltării tuturor ființelor vii și joacă un rol important în privința schimbărilor climatice globale, cum ar fi influența asupra cantității de dioxid de carbon din atmosferă (Xiao et al. 2004). Cartografierea vegetației aduce un plus de informație necesară pentru înțelegerea și evaluarea mediului înconjurător natural și al celui influențat de om.

Metodele tradiționale de evaluare a stării stratului de vegetal (studiile în teren, analiza literaturii de specialitate, interpretarea hărților) nu sunt metode eficiente deoarece sunt mari consumatoare de timp , datele nu sunt de actualitate și sunt constisitoare. Teledetecția oferă o alternativă practică și fezabilă din punct de vedere economic pentru studiile stratului vegetal, în special pentru suprafețe mari. (Langley et al. 2001; Nordberg and Evertson 2003). Din acest motiv au fost întreprinse numeroase studii de către cercetători pentru dezvoltarea mijloacelor de teledetecție pentru determinarea speciilor sau comunităților de vegetație. Spre exemplu, Programul Internațional Geosfera-Biosfera a inițiat proiectul de cartare la nivel global a acoperirii terenului (*land cover*) și a fost dezvoltată o bază de date încă din 1992 , Caracterizarea Globală a Acoperirii Terenului, bazată pe imagini AVHRR cu o rezoluție de 1km. Ulterior, Joint Research Institute din Italia a implementat un proiect similar, în anul 1999, intitulat Acoperirea Globală a terenului 2000 (*Global Land Cover 2000*); pentru realizarea acestui proiect au fost utilizate imagini SPOT4-Vegetation cu o rezoluție de 1km (<http://www-gvm.jrc.it/glc2000/>).

Doi ani mai târziu NASA a lansat un nou proiect, baza de date a acoperirii terenului MODIS, bazată pe compozițiile lunare a imaginilor de pe senzorul Terra MODIS nivelurile doi și trei, între Ianuarie și Decembrie 2001 (<http://duckwater.bu.edu/lc/mod12q1.html>). La o scară mai mică, Proiectul Pan-European de Monitorizare a Acoperirii Terenului care și-a propus realizarea unei baze de date pan-

europene cu rezoluția de 1km a fost inițiat în 1996 și s-a bazat pe imagini satelitare NOAA-AVHRR precum și pe date auxiliare (Rounsevell et al. 2006). În afară de aceste seturi de date la nivel global sau continental au mai existat anumite inițiative pentru crearea unor baze de date la nivel regional sau național. Spre exemplu Cartarea Vegetației de către Serviciul Național al Parcurilor împreună cu Serviciul de Prospectări Geologice al Statelor Unite ale Americii a fost un program de colaborare care a început în 1994 cu scopul de a produce hărți digitale detaliate pentru parcurile naționale; s-au folosit imagini produse de spectrometrul aerian pentru vizibil și infraroșu (AVIRIS), precum și date locale preluate din teren. Tehnologia teledetecției poate fi folosită pentru cartarea vegetației pe uscat, dar și pentru zonele costiere sau inundabile cu populații de vegetație acvatică submersă; acest tip de vegetație este un indicator important în privința condițiilor de mediu din ecosistemele acvatice (Lathrop et al. 2006; Wolter et al. 2005).

Pigmenții plantelor, clorofila de tip a și b, absorb puternic radiația electromagnetică în regiunile albastru (450nm) și roșu (670 nm) ale spectrului și utilizează energia pentru fotosinteză. În plus, frunzele sănătoase reflectă energia în benzile de infraroșu apropiat cuprinse între 700 și 1300 nm (Jensen, 2000; Lillesand et al., 2008). Caracteristicile spectrale distinctive ale plantelor verzi, reflectanță slabă în spectrul vizibil și puternică în infraroșu apropiat, au fost folosite pentru cartografierea, monitorizarea și managementul resurselor vegetale, cât și pentru definirea unor indicatori simpli, precum indicele simplu de vegetație (SVI) sau indicele normalizat de diferențiere a vegetației (NVDI). Simplitatea și flexibilitatea acestor indici permit compararea datelor obținute în condiții de iluminare diferite (Walters et al., 2008). Indicele normalizat de diferențiere a vegetației (NVDI) a fost sugerat de Rouse et. al (1973) și este printre primii, dar și cei mai populari indici de vegetație. Este folosit pentru minimizarea efectelor atmosferice prin raportarea diferenței dintre benzile roșu și infraroșu apropiat la cantitatea totală de radiație. Valorile acestui indice au fost asociate cu diferite caracteristici ale plantelor precum tipul de vegetație (Geerken et al., 2005), conținutul de apă al vegetației (Jackson et al., 2004), biomasa și productivitatea sau concentrația de clorofilă (Wu et al., 2008).

Vegetația acvatică submersă reprezintă un grup aparte de plante care se dezvoltă în apele costiere sau în cele din zone inundabile. Acest tip de vegetație se constituie într-o componentă vitală pentru sistemele ecologice acvatice. Teledetecția reprezintă un instrument important pentru monitorizarea acestui tip de habitat deoarece poate aduce informații din zone greu accesibile sau îndepărtate. Rezoluția spațială a acestor sisteme variază între 30 de metri pentru Landsat Thematic Mapper și 2.4 m pentru imagini Quickbird, dar poate coborâ până la 1 m sau chiar mai puțin în cazul sistemelor de

teledetecție instalate în aeronave. Au fost mai multe proiecte de cercetare care au folosit imagini Landsat pentru cartografierea habitatelor costiere (Khan et al., 1992), a zonelor cu recife de corali (Mishra et al., 2005, 2006), evaluarea florei și faunei de pe fundul lacurilor (Matsunaga & Kayanne, 1997), sau pentru analiza temporală (Matsunaga & Kayanne, 1997). Cartografierea vegetației acvatice submerse este realizată prin mijloace de clasificare supervizată și nesupervizată bazate pe variațiile semnalului în domeniul multispectral, în principal în domeniul undelor scurte din domeniul vizibil care penetrează apa într-o măsură mai mare (Maeder et al., 2002; Pasqualini et al., 2005). Regiunea de spectru din infraroșu apropiat este folosită mai rar datorită atenuării mări a apei; totuși, în cazul clasificării supervizate, dacă se face riguros alegerea zonelor de antrenament pentru procesul de clasificare și dacă comunitățile de plante acvatice submerse sunt dense, apa este limpede, iar adâncimea este constantă se pot folosi se pot observa diferențe spectrale și în infraroșu apropiat. În alte cazuri se pot folosi modele de transfer radiativ pentru corecția unghiului de incidență a luminii solare, a perturbațiilor atmosferice, a tipului de substrat și a adâncimii, dar pentru asta sunt necesare multe măsurători în teren. Majoritatea modelelor de transfer radiativ disponibile a fost folosită pentru cartografierea vegetației submerse în medii avatice cu turbidități foarte scăzute și nu a putut fi corectat corespunzător efectul de atenuare a apei în domeniul infraroșu (Ciraolo, 2006; Brando et al., 2009).

Cunoașterea proprietăților optice ale coloanei de apă poate ajuta la eliminarea schimbărilor de reflectanță în funcție de variabilitatea adâncimii acesteia. Mishra et. al (2005) a demonstrat că pentru a determina cu precizie albedoul substratului folosind un model de transfer radiativ trebuie cunoscute proprietățile optice ale apei (absorbția, împrăștierea) din zona de studiu. Același autor a arătat că semnalul înregistrat de un senzor deasupra apei este puternic influențat de abundența fitoplanctonului, interacțiunea cu apa, precum și de energia reflectată de substrat. Totuși, este complicat să se măsoare cu acuratețe toate aceste proprietăți optice datorită problemelor de ordin logistic și al erorilor instrumentelor de măsură.

Odată cu dezvoltarea senzorilor care permit achiziția imaginilor hiperspectrale și a instrumentelor software necesare prelucrării acestora au apărut noi posibilități de cartografiere a vegetației acvatice. În timp ce imaginile satelitare sunt înregistrate la intervale fixe, dependente de orbita satelitului, colectarea și procesarea imaginilor hiperspectrale poate fi costisitoare. Din acest motiv Finkbeiner et al (2001) a sugerat mai multe criterii pentru alegerea momentului achiziției: momentul cel mai propice este în timpul verii, când biomasa acestui tip de vegetație atinge valoarea maximă, imaginile trebuie înregistrate când apa are turbiditate scăzută, când vântul nu bate cu putere deoarece poate

determina creșterea turbidității apei, momentul cel mai propice este atunci când unghiul solar de incidență este între 30-45 de grade, când gradul de acoperire cu nori este cât mai scăzut, iar mostrele în teren trebuie colectate în același timp cu achiziția imaginilor aeriene. De asemenea, munca de teren trebuie să includă măsurători complexe, de reflexie, turbiditate, măsurători ale parametrilor chimici ai apei (pH, concentrația diversilor compuși).

Răspunsurile spectrale distincte sunt folosite pentru definirea zonelor de antrenament pentru algoritmi de clasificare. Clorofila și alți pigmenți se găsesc în toate speciile de plante acvatice, însă raporturile dintre reflectanță în diferite benzi hiperspectrale diferă de la specie la specie, precum și în funcție de condițiile locale de mediu (Govender et al., 2009).

1.2 Lucrări pe plan național

Pe plan național există mai multe lucrări care se concentrează pe studiul populațiilor de vegetație acvatică submersă, în special în legătură cu zonele umede din Delta Dunării. Lacurile puțin adânci din zonele inundabile formează un mediu propice pentru dezvoltarea acestui tip de vegetație. Compoziția și extinderea arealului acestor populații sunt o reflexie a influenței apei fluvului în lacuri. Apele Dunării, bogate în nutrienți și sedimente în suspensie ajung în lacuri prin canale sau pur și simplu prin deversare în perioadele de inundații. Coops et al (1999) realizează un studiu în care sunt scoate în evidență legăturile dintre fluxurile de apă din fluviu și dezvoltarea comunităților de plante acvatice submerse din lacurile din Delta Dunării. Sunt folosite imagini Landsat precum și o multitudine de date din teren și cunoștințe locale despre ecosistemele implicate. Pentru realizarea studiului sunt culese multe mostre din diferite tipuri de lacuri din deltă. Sunt evaluate tipurile de vegetație, densitatea comunităților de vegetație submersă, adâncimea apei, transparența și distanța față de brațele Dunării, tipul de sedimente. În urma procesului de clasificare supervizată lacurile au fost împărțite în 3 mari categorii: lacuri cu apă limpede, lacuri intermediare și lacuri cu turbiditate ridicată; fiecărei categorii îi corespund grupuri distincte de vegetație submersă.

Niculescu et al (2014) realizează un studiu despre populațiile și structurile vegetale din zonele umede ale deltei folosind măsurători LIDAR în conjuncție cu imagini RADARSAT-2 precum și clasificarea supervizată a imaginilor SPOT-5 folosind algoritmul Spectral Angle Mapper. Măsurătorile LIDAR au oferit date de o acuratețe ridicată în legătură cu înălțimea vegetației, interpretarea măsurătorilor RADARSAT-2 a dus la crearea unei imagini suplimentare în privința structurii vegetației, iar clasificarea

imaginilor SPOT-5 s-a făcut utilizând date din teren achiziționate folosind spectrometre pentru calibrarea zonelor de interes.

CAPITOLUL 2

TEHNICA DE LUCRU ȘI METODOLOGIA

2.1 Delta Dunării - caracteristici generale

Delta Dunării este situată în partea de sud-est a Europei și se întinde în proporție de aproximativ 90 % pe teritoriul României, iar restul de 10% se află pe teritoriul Ucrainei. Dunărea cel mai mare fluviu al Uniunii Europene, atât ca suprafață a bazinului cât și ca debit, și formează o deltă care în amonte de orașul Tulcea unde fluviul se desparte în brațul Chilia, la nord, și brațul Tulcea către sud. În aval de același oraș fluviul se mai desparte în alte două brațe, Sulina și Sfântul Gheorghe. În afară de zona dintre brațele Dunării, delta cuprinde și ariile inundabile dintre Tulcea și Isaccea, complexul lagunar Razim-Sinoe, precum și și delta secundară formată la nord de brațul Chilia.

Suprafața rezervației biosferei Delta Dunării este de aproximativ 5850 km², dintre care 46 km² se află pe teritoriul Ucrainei (Hanganu et. al, 2002). Întinderile de apă și uscat creează condiții de viață bune pentru un număr impresionant de specii de plante și de animale. Vegetația acvatică are o pondere importantă în totalul speciilor de plante din deltă și se poate împărți în două mari categorii: vegetație acvatică submersă și vegetație acvatică flotantă. Dezvoltarea acestui tip de vegetație se află în strânsă legătură cu evoluția hidrologică a fluviului care are un tipar de descărcare ciclic, cu maxime în lunile mai, iunie și minime în lunile de toamnă. Debitul Dunării este drenat în proporție de aproximativ 60% de brațul Chilia, 15% de brațul Sulina și 25% de brațul Sfântul Gheorghe.

Cantitatea de sedimente transportată s-a modificat substanțial în ultimii 60 de ani de la aproximativ 70 milioane de tone pe an înainte de 1960 și de construcția barajului de la Porțile de Fier I, până la 25 milioane de tone pe an la începutul anilor 90 (Giosan et. al, 2013). În același timp, cantitatea de nutrienți a crescut în același interval datorită modificărilor produse de om pe cursul fluviului. Aceste aspecte au produs anumite modificări în ecosistemele din deltă, dezvoltarea vegetației acvatice fiind influențată într-o măsură mai mare.

Nivelul suprafeței deltei scade de la 3,7 metri în amonte de orașul Tulcea la 0,5 metri la gura de vărsare a brațului Sulina. În timpul inundațiilor care au loc primăvară și vara nivelul apei poate crește cu până la 1,5 metri în amonte de Tulcea sau cu 0,3 metri la Sulina. Înaintea construirii digurilor, lacurile de la nord de brațul Chilia și cele de la sud de brațul Sfântul Gheorghe comunicau cu fluviul suprafața inundabilă depășind 4500 km² , iar volumul de apă acumulat putea fi de aproximativ 7

milioane de metri cubi (Petrescu, 1963). Sedimentele sunt depozitate de-a lungul malurilor brațelor principale ale fluviului, iar în interiorul deltei acestea se depun mai rapid datorită vitezelor de curgere scăzute, apa devenind transparentă. În acest fel, acumulările aluvionare duc la o creștere a nivelului uscatului cu 2-3 cm pe an (Banu și Rădulescu, 1965), dar datorită proceselor epirogenetice de scufundare din regiune (Bertman, 1964; Banu și Buzeteanu, 1966) aceste acumulări sunt compensate.

Clima în Delta Dunării este temperat continentală, cu ierni scurte și blânde și cu veri de durată și calde (Rudescu et. al., 1965). Este influențată de interacțiunea maselor atmosferice din zonele Oceanului Atlantic, Mării Mediterane și din zona eurasiatică (Diaconu & Iacov, 1963; Petrescu, 1963). Temperatura medie a lunii Ianuarie fluctuează între -9 și +5° Celsius, iar în iunie între 22,3-23,0° Celsius (Bilyk, 1977; Gastescu, 1996). Primul îngheț apare toamna, între 15 și 30 Octombrie, iar ultimul are loc primăvara, între 10 și 15 Aprilie. Numărul zilelor cu o temperatură medie zilnică de peste 10° Celsius este între 170 și 200 pe an, în intervalul Aprilie - Octombrie (Shvebs, 1979). Apa dulce poate îngheța parțial în timpul iernii, însă înghețul complet este extrem de rar, în iernile foarte grele, atunci când temperaturile coboară până la -25 to -27° Celsius.

Cantitatea anuală de precipitații este de 350-400mm pe an, iar evaporația este de 800-1000 mm pe an. O evaporare atât de mare ar trebui să conducă la creșterea suprafețelor de apa saturate în clorați și sulfați și la salinizarea solurilor umede. Salinizarea este observată doar în zonele modificate de om, în rest fiind evitată în mod natural de capacitatea de inundare a Dunării din timpul inundațiilor de primăvară și al celor ocazionale, de toamnă.

2.2 Vegetația acvatică

Populațiile de plante acvatice din Delta Dunării cuprind un număr mare de specii care ocupă periodic anumite nișe ecologice. Distribuția acestora este influențată de anotimp, de periodicitatea inundațiilor, de stabilitatea habitatului, este determinată de procese de eroziune și acumulare, de factori antropici și de vârsta habitatului. Plantele anuale apar în perioada primăverii, în lacuri și în zonele de acumulare a apei, iar evoluția acestora are legătură cu inundațiile din această perioadă a anului, iar vegetația lemnoasă se dezvoltă în zonele mai stabile din punct de vedere morfologic.

Vegetația erbacee este influențată în mare măsură de procesele de eroziune și de cele de acumulare. Partea superioară a zonelor de sedimentare oferă suport pentru acest tip de vegetație. În același timp, plantele stabilizează și pot accelera procesul de depozitare. Dezvoltarea lor este influențată de acțiunea curenților. În acest mod, zonele propice dezvoltării vegetației acvatice se modifică de la an la an. Lacurile puțin adânci situate în zonele inundabile sunt deseori populate de vegetație acvatică submersă sau plutitoare. Distribuția speciilor și întinderea acestora reflectă influența apei din fluviu în aceste lacuri (Van den Brink et al., 1991; Janauer & Kum, 1996). Hidrologia și morfologia zonelor inundabile determină curgerea fluxurilor de apă dintre Dunăre înspre lacuri și în sens invers. Influxul de apă din fluviu din timpul primăverii poate fi considerat forța mobilizatoare a ecosistemului acvatic, iar impactul acestuia variază în funcție de diferențele dintre căile de acces, de timpul de rezidență și de dimensiunea suprafețelor inundate. Zonele inundabile din apropierea brațelor Dunării sunt influențate într-o măsură mai mare față de lacurile izolate. Canalele artificiale își aduc și ele contribuția în dirjarea fluxurilor de apă.

Lumina și nutrienții sunt principalii factori care controlează dezvoltarea vegetației acvatice în lacuri (Spence, 1982; Chambers, 1987). Fluxurile de apă cu o cantitate mare de materie în suspensie și cu mulți nutrienți determină creșterea turbidității apei, ceea ce poate împiedica dezvoltarea vegetației submerse. Pe de altă parte, prezența acest tip de vegetație poate avea un impact puternic în privința transparenței apei (Van den Berg et al., 1997).

Vegetația acvatică submersă reprezintă un grup de plante care aduce o contribuție vitală proceselor ecologice din zonele umede, dinamicii și productivității acestora. Acestea oferă un habitat propice dezvoltării anumitor specii de pești, le oferă protecție împotriva prădătorilor, se constituie în hrană pentru anumite specii, absorb energie luminoasă și nutrienți, produc oxigen și îmbunătățesc claritatea apei, și ajută la depunerea sedimentelor în suspensie din apă prin stabilizarea acestora pe substrat (Jin, 2001; Findlay et al., 2006). Din aceste motive distribuția, compoziția și abundența acestui tip de vegetație acvatică prezintă interes și reprezintă un bun indicator al calității mediului acvatic. În figura următoare se poate observa o comunitate restrânsă de *Potamogeton crispus* la marginea canalului Uzlina.



Foto 2.1 - Comunitate de *Potamogeton crispus* la marginea canalului Uzlina

2.3 Teledetecție aplicată pentru determinarea speciilor de plante acvatice submerse

Principiile din spatele caracteristicilor spectrale ale vegetației sunt aceleași atât pentru plantele acvatice cât și pentru cele terestre. La nivelul frunzelor, prezența pigmentilor determină un anumit răspuns în domeniul vizibil al spectrului, iar morfologia frunzelor împreună cu cantitatea de apă din jurul acestora determină răspunsul în benzile din infraroșu. La nivel individual, sunt importanți factori biofizici precum distribuția frunzelor, densitatea și orientarea lor și structură generală. La nivelul grupurilor de plante, biomasa și densitatea acestora sunt alte variabile importante. Deși răspunsul spectral al platelor acvatice seamna cu cel al plantelor terestre prezența apei în jurul acestora influențează răspunsul caracteristic. Din acest motiv este importantă distincția clară a plantelor submerse față de cele de suprafață sau terestre.

Mai multe studii au arătat că regiunile din spectru importante pentru detecția vegetației submerse se află în zona culorii verzi, apoi roșu și infraroșu apropiat. Totuși, trebuie avut în vedere faptul că prezența apei atenuează o mare parte din răspunsul spectral al plantelor în regiunile vizibil și infraroșu. În figură 2.2 este reprezentată dependența răspunsului spectral al plantelor față de adâncimea de submersie.




Fig. 2.1 - Variația reflectanței vegetației acvatice submerse în funcție de adâncime. Graficul este valabil pentru apa limpede, cu adâncimi între 10 și 50 cm (sursa: Hyun Jung, Cho, D. Mishra, and J. Wood. *Remote Sensing of Submerged Aquatic Vegetation*)

Se poate observa cum răspunsul spectral al vegetației submerse se apropie din ce în ce mai mult de cel al apei odată cu creșterea adâncimii. În afară de apă, prezența altor substanțe active din punct de vedere optic (sedimente în suspensie, molecule organice, plancton) influențează reflexia, împrăștierea și absorbția radiațiilor electromagnetice. În plus, reflectanța substratului este un alt factor care trebuie luat în considerare când se face interpretarea semnalului radiometric pentru analiza vegetației în apele puțin adânci. Gradul de dezvoltare al vegetației este un alt element care contribuie la modificarea răspunsului spectral al acesteia; astfel, plantele aflate la începutul ciclului de viață vor avea caracteristici spectrale diferite față de un moment apropiat sfârșitului ciclului anual.

2.4 Aria de studiu

Aria de studiu aleasă este întreaga arie a rezervației biosferei Delta Dunării de la est de lacurile din zona inundabilă Isaccea-Tulcea. Zona aleasă pentru culegerea datelor din teren este reprezentată de lacurile Isaac și Uzlina. A fost aleasă această zonă datorită accesibilității ei. Deplasarea s-a făcut prin mijloace auto până la Murighiol, după care s-a folosit caiacul pentru deplasarea în zonele acoperite de apă.



Fig. 2.2 - Aria de studiu

2.4.1 Date din teren

Pentru observarea situație din teren și înregistrarea zonelor în care sunt prezente comunități de vegetație acvatică submersă am efectuat o deplasare în teren în perioada 26-28 mai 2015 în zona lacurilor Uzlina și Isaac. Întinderea ariei în care am făcut înregistrări a fost deteminata și de mijloacele de deplasare avute la dispoziție: caiac. În figură de mai jos se pot vedea detalii cu privire la zona vizitată. Fotografiile 2.2 și 2.3 prezintă câteva aspecte din regiunea vizitată.



Fig. 2.3 - Aria de studiu în teren



Foto 2.2 - Vegetație acvatică submersă pe lacul Uzlina și un pelican în plan îndepărtat



Foto 2.3 - Locul de campare la marginea lacului Isaac

2.5 Imagini de teledetecție folosite

2.5.1 Achiziționarea imaginilor

Pentru studiul prezentat în această lucrare s-au folosit imagini înregistrate de senzorul Landsat 8 corespunzătoare datei din 24 Mai 2015 și imagini ale senzorului Landsat 7 ETM+ din data de 1 Iunie 2015. Imaginile folosite aparțin orbitei 181, rândurile 28 și 29. Cele două imagini au fost combinate într-un mozaic folosind ENVI 5.0, apoi scena rezultată a fost delimitată astfel încât să cupinda doar aria în care era inclusă zona de studiu. În cazul imaginilor Landsat 7 s-a realizat procesul de umplere a golurilor folosind utilitarul Landsat GapFill din ENVI 5.0 pentru corectarea zonelor din marginile scenei satelitare. Imaginile au fost obținute de pe site-ul <http://earthexplorer.usgs.gov/>.

2.5.2 Procesarea imaginilor

Procesarea imaginilor a constat în prcurgerea următoarelor etape: crearea mozaicului alcătuit din cele două imagini, apoi delimitarea scenei rezultate. Datorită faptului că am folosit două imagini succesive preluate de același senzor în aceeași zi, a faptului că am folosit metode de clasificare supervizată și a faptului că în aria de studiu nu exista elemente topografice care să altereze răspunsul spectral al zonelor studiate (văi, pante) nu am rulat niciun proces de rectificare radiometrică.

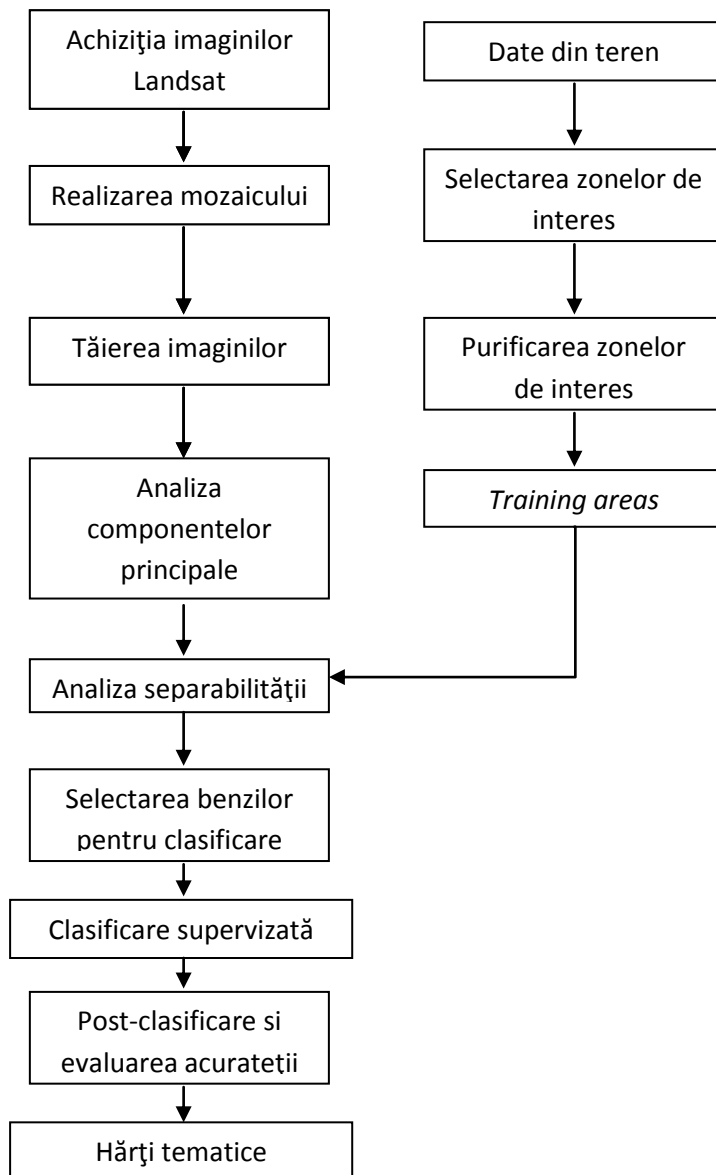


Fig. 2.4 - Etape de lucru

După această procedură am trecut la procesarea componentelor principale, la definirea zonelor de interes și la evaluarea răspunsului acestora în diferite benzi. Apoi am realizat purificarea zonelor de interes, s-au rulat pocesele de clasificare supervizată și am evaluat acuratețea rezultatelor pe baza

datelor culese din teren și nefolosite la definirea zonelor de interes. Figura 2.4 prezintă etapele parcurse.

2.5.2.1 Pre-Procesarea imaginilor

Cele două imagini au fost deschise în ENVI 5.0 și s-a rulat procesul de realizarea a mozaicului pe baza imaginilor goreferentiate. Cele două imagini sunt în sistem de coordonate UTM, zona 35N, și folosesc ca datum de referință WGS-84. După obținerea mozaicului s-a realizat manual vectorul de delimitare a ariei studiate care urmărește cu aproximație limitele rezervație biosferei Delta Dunării. Acest vector a servit la tăierea mozaicului obținut și , ulterior, la mascarea zonei de studiu. Imaginea a fost tăiată astfel încât să cuprindă doar aria de studiu.

Pentru îmbunătățirea rezultatelor obținute a fost necesară crearea unei măști pentru suprafețele acoperite de apă. Pentru aceasta s-au calculat indicii normalizat de diferențiere a apei (NDWI) și indicii normalizat modificat de diferențiere a apei (MNDWI):

$$NDWI = (Green - NIR) / (Green + NIR),$$

$$MNDWI = (Green - MIR) / (Green + MIR),$$

unde Green - reprezintă banda 3, asociată culorii verzi, NIR - banda 4, infraroșu apropiat, MIR - banda 5, infraroșu.

Indicele NDWI ia în calcul reflectanța apei în banda verde, absorbția ei în banda de infraroșu apropiat, precum și reflectanța ridicată în infraroșu apropiat a vegetației și a solului. În zonele acoperite de apă indicii va avea valori pozitive, iar în cele acoperite de sol sau vegetație va avea valori negative (Peng Li et. al, 2013).

Indicele modificat, MNDWI, ține cont de faptul că apa absoarbe și mai multă energie în banda 5, infraroșu, decât în infraroșu apropiat. Deoarece solul reflectă mai multă energie în banda 5, iar vegetația reflectă mai multă energie în banda 5 decât în banda 3, contrastul dintre zonele acoperite de apă și cele acoperite de sol sau vegetație va fi mai mare (Peng Li et. al, 2013).

În cazul imaginii Landsat 8 a fost necesară calcularea unor indici suplimentari pentru eliminarea efectelor norilor. Prin simpla folosire a celor doi indici o parte din umbrele acestora au fost incluse în zonele acoperite de apă. Au fost calculați următorii trei indici suplimentari:

$$I_1 = 0,846 \times B_2 - 0,073 \times B_3 - 0,46 \times B_4 - 0,0032 \times B_5 - 0,049 \times B_6 + 0,0119 \times B_7 \text{ (Kong et. al, 2013),}$$

$$I_2 = (B_1 - B_3) / B_1 \text{ (Hallahan et. al, 2013),}$$

și

$$I_3 = B_5 / I_1$$

unde B_i , $i=1,2,...,8$ reprezintă benzile imaginii Landsat 8 conform tabelului de mai jos:

Tabelul 2.1 - Lista benzilor senzorului Landsat 8

Banda	Nume	Lungime de undă (nm)	Rezoluție (m)
1	Coastal/Aerosol	435-451	30
2	Albastru	452-512	30
3	Verde	533-590	30
4	Roșu	636-673	30
5	Infraroșu apropiat	851-879	30
6	Infraroșu unde scurte 1	1566-1651	30
7	Infraroșu unde scurte 2	2107-2294	30
8	Pancromatic	503-676	15
9	Cirrus	1363-1384	30

S-a încercat utilizarea algoritmului Fmask (Zhe Zhu et. al, 2011), dar nu a returnat rezultate satisfăcătoare. Acest procedeu ține cont de unghiul de incidență al razelor solare în momentul achiziționării imaginii și presupune calcularea altitudinilor limitelor inferioare și superioare a norilor cirrus, apoi, prin calcul geometric, se estimează proiecțiile umbrelor acestora. În cazul imaginilor folosite se pare că acest algoritm nu a funcționat corect, altitudinea norilor fiind subestimată. Proiecțiile umbrelor returnate de algoritm au apărut mult mai aproape de nori față de umbrele observate în imagine.

2.5.2.2 Procesarea componentelor principale și definirea zonelor de interes

Această etapă a fost realizată folosind software ENVI 5.0.

Analiza componentelor principale presupune rularea unor transformări matematice aplicate pixelilor imaginii. În urma acestui procedeu se va obține o nouă imagine, cu același număr de benzi ca cea inițială, dar care va avea caracteristici spectrale diferite. Primele componente vor prezenta un grad de decorelare accentuat.

Spre exemplu, într-o imagine care conține zone acoperite de vegetație, benzile din spectrul vizibil, mai ales roșu și albastru, vor fi puternic corelate deoarece reflectanța plantelor în aceste benzi este scăzută. În urma analizei componentelor principale se va obține o imagine nouă, ale cărei benzi vor prezenta grade de detaliu diferite, descrescător de la prima componentă către ultimele. Figurile 2.3 și 2.4 reprezintă o parte din pădurea Letea situată la vest de grindul cu același nume și o zonă de vegetație de la nord de lacul Merhei. În prima reprezentare apar în tonuri de gri benzile din spectrul vizibil și combinația RGB dintre acestea, iar în cea de-a doua apar primele patru componente principale în tonuri de gri. Se observă că prima componentă principală conține cele mai multe detalii, iar componenta cu numărul patru cele mai puține.




Fig. 2.5 - Imaginea zonei de nord a pădurii Letea în tonuri de gri pentru benzile albastru, verde, respectiv roșu, de la stânga spre dreapta, și reprezentarea RGB




Fig. 2.6 - Imaginea zonei de nord a pădurii Letea în tonuri de gri pentru componentele principale unu, doi, trei și patru, în această ordine, de la stânga spre dreapta

Definirea zonelor de interes s-a realizat folosind datele culese din teren. Înregistrările GPS au fost vectorizate și încărcate în aplicație. Apoi s-a realizat analiza răspunsului spectral al fiecărei zone de interes pe imaginea primară și pe componentele principale.

S-au definit mai multe clase: *vegetație, sol și dune, apă limpede, apă cu turbiditate ridicată, macrofite, nori*. Zonele de interes au fost rafinate folosind procedura descrisă de R.A. Schinwengerdt (1997). Acesta presupune clasificarea nesupervizată a pixelilor care formează regiunile de interes. În urma acestui proces de clasificare se poate decide eliminarea unor pixeli ale căror caracteristici spectrale diferă cu mult față de majoritatea celorlalți pixeli.

Atât înainte cât și după rafinarea zonelor de interes s-a realizat analiza separabilității claselor și s-a observat îmbunătățirea acestora în urma procesului de purificare. Analiza s-a făcut pe graficele care reprezintă răspunsul spectral mediu al fiecărei clase în toate cele 8 benzi ale imaginii Landsat 8. În urma acestei analize s-a decis eliminarea benzii 6 din procesul de analiză datorită unei separabilități foarte scăzute între clase.

2.5.2.3 Clasificarea imaginilor

După rularea procedurilor de pre-procesare și preclasificare s-a testat performanța mai multor algoritmi de clasificare supervizată: *Maximum Likelihood, Minimum distance, Paralelipiped, Spectral Angle Mapper și Neural Net*.

Maximum likelihood

Este una din tehnicile cele mai folosite pentru clasificarea imaginilor de teledetectie (Richards, 1986). În natură, ariile care trebuie clasificate prezintă o anumită variație în răspunsurile spectrale. În plus, norii, umbrirea topografică, zgomotul sistemului și efectul pixelilor amestecați măresc această variabilitate. Prin acest procedeu de clasificare se calculează mediile și distribuțiile spectrale ale fiecărei clase, iar pentru pixelii din afara regiunilor definite de utilizator se calculează probabilitatea ca aceștia să aparțină unei anumite clase. Pixelul este adăugat clasei pentru care

probabilitatea de apartenență este cea mai ridicată. În acest fel, toți pixelii vor aparține unei clase. Această metodă este consumatoare de resurse de procesare și este destul de sensibilă în ceea ce privește calitatea zonelor de interes. Din acest motiv ariile de interes trebuie definită cu grijă. Se poate recurge la rafinarea zonelor de interes înainte de rularea acestei metode.

Minimum distance

În această metodă se calculează valorile medii ale răspunsului spectral al fiecărei clase. Pentru pixelii din afara zonelor de interes definite se calculează distanța multidimensională până la media fiecărei clase. Pixelii sunt adăugați clasei pentru care distanța calculată este minimă. Este o metodă simplă, care nu necesită o putere de calcul foarte mare, dar acuratețea ei poate lăsa de dorit.

Paralelipiped

Această metodă se bazează pe gama valorilor spectrale ale pixelilor din zonele de interes definite. Se analizează dacă pixelii care trebuie clasificați se încadrează într-una din clasele definite. În caz afirmativ se ei sunt adăugați clasei respective, altfel rămân neclasificați. Această metodă prezintă probleme de acuratețe în cazul claselor care se suprapun din punct de vedere spectral.

Spectral angle mapper

Această tehnică presupune calcularea mediei valorilor pixelilor din zonele de interes în spațiul multispectral. Mai apoi, pentru fiecare pixel, se calculează unghiul din domeniul multispectral dintre fiecare pixel care trebuie clasificat și mediile claselor definite. Unghiul maxim poate fi setat diferit pentru fiecare clasă în parte. Prin acest procedeu, în funcție de valoarea unghiului maxim, pot fi clasificați toți pixelii sau doar o parte dintre aceștia. Această metodă prezintă un grad ridicat de precizie în cazul zonelor de interes cu o dispersie relativ mică a valorilor răspunsurilor spectrale ale pixelilor componenți.

Neural Net

Rețelele neuronale artificiale sunt compuse din mai multe straturi: cel de intrare, cel de ieșire și unul sau mai multe straturi ascunse. Elementele acestor straturi se numesc neuroni și sunt interconectate prin multe legături așa cum apare în figură de mai jos. Procesul de antrenament al acestui algoritm constă în ajustarea coeficienților fiecărei legături dintre neuroni. În acest studiu am folosit o versiune simplificată a acestui algoritm, cu două straturi, unul de intrare și unul de ieșire.

2.5.3 Post-Clasificarea imaginilor

După rularea procedurilor de clasificare rezultatele obținute trebuie prelucrate pentru îmbunătățirea lor și pentru evaluarea acurateții. În acest scop s-au rulat procedee de rafinare.

Strângerea în grupuri (*Clumping*) este un procedeu care ține cont de relațiile spațiale dintre pixelii rezultați în urma clasificării. Astfel, dacă un grup de pixeli este mai mic decât o limită impusă acesta este reclasificat într-una din clase care îl înconjoară. Sortarea (*Sieving*) presupune detectarea grupurilor de pixeli din grupuri mai mici decât o limită prestabilită. Aceste grupuri sunt scoase în afara oricărei clase. Sortarea rezolvă problema grupurilor izolate de pixeli. Rezultatele acestui procedeu pot fi folosite ca date de intrare pentru strângerea în grupuri.

Statisticile asociate claselor obținute pot da o imagine de ansamblu asupra rezultatelor clasificării. Pentru evaluarea rezultatelor procedurilor de clasificare se generează matricea de incertitudine. Prin acest procedeu se compară clasele obținute cu anumite zone de control definite de utilizator. Se obțin date statistice cu privire la acuratețea rezultatelor, erorii de omisiune și a erorii de atribuire. Ca zone de control am folosit anumite înregistrări GPS vectorizate, dar nefolosite la definirea zonelor de interes precum și zone definite manual, în urma analizei vizuale a imaginii și a utilizării eşantioanelor generate aleator în ENVI 5.0. A fost calculat și coeficientul K definit, în linii mari conform următoarei formule: $K = (\text{obsevat} - \text{prevăzut}) / (1 - \text{prevăzut})$.

După rularea procedurilor de post-clasificare au fost realizate hărțile tematice prezentate în capitolul următor.

CAPITOLUL 3

REZULTATE ȘI DISCUȚII

3.1 Caracteristici ale comunităților de vegetație acvatică submersă determinate în teren

În timpul vizitelor din teren au fost identificate mai multe specii de vegetație acvatică submersă și flotantă. Tabelul 3.1 conține lista speciilor determinate în teren. Anexa 1 cuprinde poze cu toate speciile recunoscute.

Tabelul 3.1 - Specii identificate în teren

Denumire științifică	Denumire comună
Potamogeton pectinatus	
Potamogeton crispus	
Potamogeton trichoides	
Trapa natans	Ciulinul de baltă
Nuphar luteum	Nufărul galben
Nymphaea alba	Nufărul alb

Comunitățile evaluate prezentau caracteristici diferite în funcție de zona în care s-au dezvoltat și de speciile componente. Nuferii au fost determinați în zone cu ape mai limpezi, pe când ciulinii de baltă au fost găsiți în comunități în care erau prezente și *Potamogeton pectinatus* sau *Potamogeton crispus*, în zone cu ape cu turbiditate mai ridicată. Fotografiile 3.1 și 3.2 ilustrează comunități de nuferi și de ciulini de baltă.



Foto 3.1 - *Nuphar luteum* și *Potamogeton pectinatus*



Foto 3.2 - *Trapa natans* și *Potamogeton pectinatus*

3.2 Preprocesarea imaginilor Landsat 7

3.2.1 Umplerea golurilor, crearea mozaicului și tăierea imaginii

Cele două imagini Landsat 7, orbită 181, rândurile 28 și 29, înregistrate pe 1 Iunie 2015, au fost preprocesate pentru umplerea golurilor prin metoda triangulației (Single File Gap Fill). Valorile digitale ale pixelilor care umplu golurile sunt aproximări ale valorilor pixelilor din jur. Această metodă introduce erori suplimentare. Sistemul de proiecție geografică folosit a fost UTM, Zona 35N, Datum WGS-84. După obținerea mozaicului, imaginea a fost tăiată după vectorul creat manual pentru delimitarea Deltei Dunării. Rezultatul se poate vizualiza în figura 3.1.



Fig. 3.1 - Delta Dunării - imagine Landsat 7 tăiată conform limitelor stabilite

Datorită stadiului incipient de dezvoltare a majorității speciilor de vegetație a fost obligatorie crearea unei măști suplimentare pentru delimitarea zonelor acoperite de apă. Altfel, ar fi fost foarte greu de distins comunitățile de vegetație acvatică de celelalte tipuri de vegetație deoarece în acest stadiu toate prezintă reflectanță pronunțată în benzile verde și infraroșu apropiat. Pentru crearea acestei măști au fost calculați doi indici: indicele normalizat de diferențiere a apei și indicele normalizat modificat de diferențiere a apei.

Datorită gradului ridicat de dezvoltare a vegetației acvatice submerse din această perioadă anumite zone prezintă valori negative pentru ambii indici deși sunt zone acoperite de apă. Următoare patru figuri prezintă valorile obținute pentru fiecare dintre indici în lungul unor transecte trasate în zone cunoscute. De-a lungul transectului din zona de NV a imaginii se poate observa și traseul parcurs pe teren, și valoarea celor doi indici la intersecția cu acesta. În cazul transectului din zona de sud, punctul evidențiat pe grafic se situează în zona de separare dintre luciul de apă și suprafața acoperită de vegetație acvatică submersă cu densitate foarte ridicată.

În urma analizei celor patru transecte s-a observat că MNDWI ar fi indicele potrivit pentru crearea unei măști pentru suprafețele acoperite de apă. Alegerea unei valori mai mici decât zero ca limită inferioară pentru stabilirea zonei de mascare ar fi inclus foarte multe suprafețe neacoperite de apă, iar alegerea valorii zero ca limită inferioară a lăsat în afara măștii anumite zone acoperite de apă, dar cu o densitate foarte mare a stratului de vegetație acvatică. În consecință au fost necesare anumite corecții manuale, bazate pe cunoștințele din teren și pe interpretarea vizuală a imaginilor. Corecțiile s-au făcut doar în zona ariei de studiu.




Fig. 3.2 - NDWI - transect în zona de sud a ariei de de studiu; sensul transectului: de la dreapta spre stânga

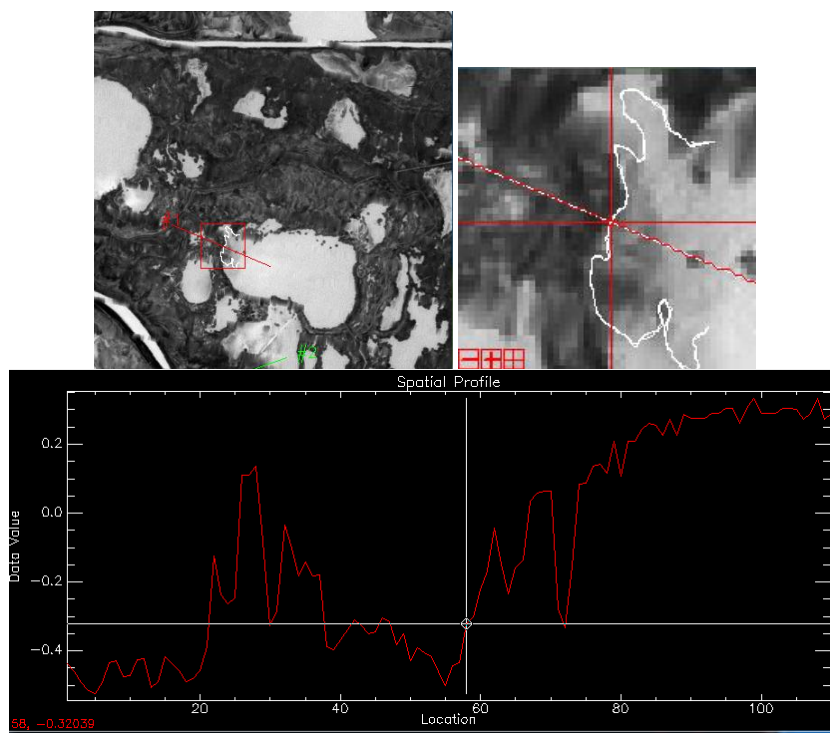


Fig. 3.3 - NDWI - transect în zona de nord-vest a ariei de studiu; se observă înregistrarea GPS a traseului parcurs în caiac




Fig. 3.4 - MNDWI transect în zona de sud a ariei de studiu; sensul transectului: de la dreapta spre stânga

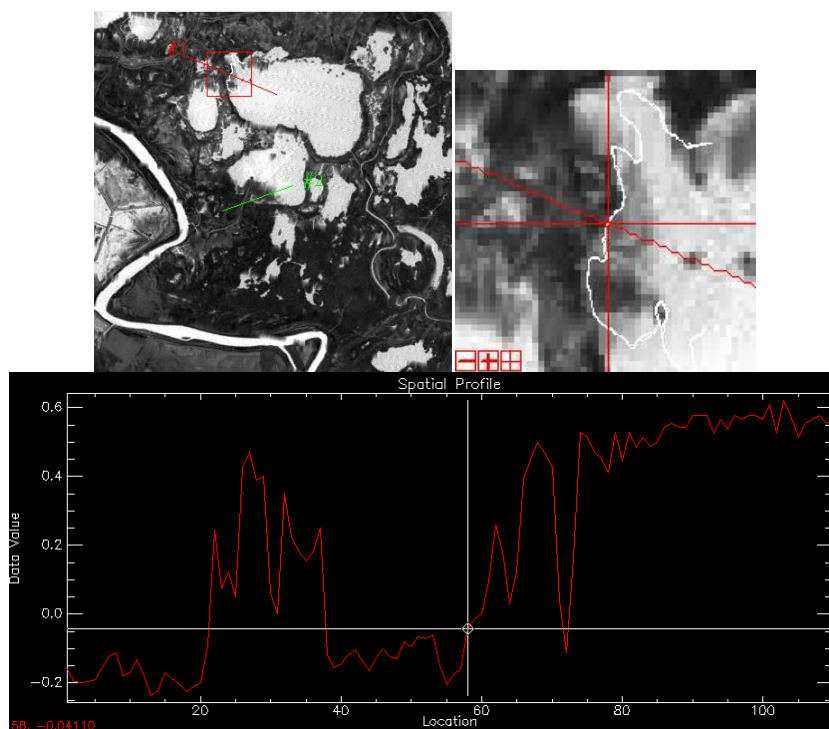


Fig. 3.5 - MNDWI transect în zona de nord-vest a ariei de studiu; se observă înregistrarea GPS a traseului parcurs în caiac

3.2.2 Analiza componentelor principale

În urma analizei componentelor principale s-a observat că doar primele 3 componente contribuie în mod semnificativ la diferențierea elementelor din imagine. În figurile 3.6 și 3.7 se pot observa valorile Eigen, precum și valorile minime, maxime, medii și deviațiile standard ale fiecărei componente. Tabelul 3.2 conține datele statistice.




Fig. 3.6 - Valorile Eigen rezultate în urma analizei componentelor principale pentru imaginea Landsat 7




Fig. 3.7 - Valorile minime, maxime (rosu), medii (alb), deviațiile standard (verde) pentru componentele principale pentru imaginea Landsat 7

Tabelul 3.2 - Date statistice rezultate în urma analizei componentelor principale pentru imaginea Landsat 7

Basic Stats	Min	Max	Mean	Stdev	Num	Eigenvalue
Band 1	-43.1344	457.0359	0	58.79378	1	3456.708889
Band 2	-87.0724	130.2284	0	17.48951	2	305.882894
Band 3	-225.666	47.28668	0	9.702744	3	94.143236
Band 4	-26.5487	65.98637	0	2.082822	4	4.338146
Band 5	-24.6838	40.12893	0	1.563138	5	2.443402
Band 6	-44.0615	42.15698	0	1.186346	6	1.407418

Componentele principale au fost utilizate pentru purificarea zonelor de interes folosite pentru clasificarea supervizată, dar și pentru delimitarea zonelor folosite la evaluarea acurateții clasificării, spre exemplu componenta 4 pentru o mai bună delimitare a zonelor cu apă cu turbiditate ridicată, așa cum apare în figura 3.8.




Fig. 3.8 - Componenta principală numărul patru afișată în tonuri de gri

3.2.3 Clasificarea imaginilor

3.2.3.1 Definirea zonelor de interes

Zonele de interes au fost definite în baza observațiilor din teren și a interpretării vizuale a imaginilor în culori naturale și utilizând componentele principale. Înregistrările GPS din jurul zonelor în care au fost găsite comunități de plante acvatice submerse au fost transformate în vectori și suprapuse peste imaginea care urma să fie clasificată.

S-a efectuat procesul de purificare a zonelor de interes, așa cum este descris de R.A. Schinwengerdt (1997). Zonele în care a fost observată prezența vegetației acvatice submerse au fost clasificate nesupervizat, prin metoda ISODATA, cu un număr minim de 5 clase și maxim de 30 de clase, în urma a 50 de iterații. Cele 17 clase rezultate au fost combinate astfel încât să rezulte doar patru, iar rezultatul a fost transformat în zone de interes. În figură 3.9 se pot observa cele trei din patru clase care au fost folosite la aria 1 a zonei de interes de vegetație acvatică submersă, reprezentate de culorile galben, violet și albastru, precum și cele 17 clase neprelucrate. În afară de aceasta a mai fost definită prin același procedeu o altă zonă situată mai la nord.




Fig. 3.9 - Clasificarea nesupervizată ISODATA pentru purificarea zonelor de interes: stânga - înainte de combinarea claselor, dreapta - cele patru clase finale

Pentru clasificarea întregii arii a deltei au fost alese următoarele zone de interes: apă limpede, apă cu turbiditate ridicată, vegetație acvatică submersă pentru zonele acoperite de apă, iar pentru zonele de uscat au fost definite zonele sol și dune, vegetație (cuprinde toate zonele de vegetație de pe uscat, inclusiv păduri) și nori. În figură următoare se pot observa o parte din zonele de interes definite.




Fig. 3.10 - Zone de interes definite: albastru - apă limpede, galben - apă cu turbiditate ridicată, verde deschis - vegetație acvatică submersă, brun - sol și dune, verde închis - vegetație, albastru deschis - nori

3.2.3.2 Analiza separabilității

Analiza separabilității pentru zonele de interes definite a permis identificarea seturilor de date potrivite pentru o separare cât mai corectă a claselor. Dealtfel, o parte din zonele de interes au fost definite complet după mai multe iterații urmate de analiza separabilității. În următoarea figură se pot observa valorile medii pentru fiecare zonă de interes și pentru fiecare bandă.




Fig. 3.11 - Valori medii ale zonelor de interes în funcție de bandă

În urma analizei valorilor medii se poate trage concluzia că ar putea apărea dificultăți în privința clasificării vegetației din zonele uscate și a vegetației acvatice submerse. Se observă că răspunsul celor două clase diferă destul de puțin, doar în benzile 4 și 5, infraroșu, unde vegetația din zonele uscate prezintă o reflectanță mai ridicată față de vegetația acvatică. Acest lucru se întâmplă datorită atenuării apei. Totuși, din cauza stadiului incipient de dezvoltare și a densității plantelor din comunitățile submerse reflectanta în infraroșu o depășește cu mult pe cea a apei. Din acest motiv, o parte din zonele acoperite de apă au fost excluse prin folosirea măștii definite prin procedeul din secțiunea 3.2.1 și a fost

necesară o corecție manuală în aria de interes. În celelalte zone nu s-a făcut niciun fel de corecte datorită lipsei datelor reale din teren.

Figura următoare prezintă deviațiile standard pentru aceleași clase, în funcție de bandă.




Fig. 3.12 - Deviații standard ale zonelor de interes în funcție de bandă

Se poate observa că zonă de interes pentru vegetație acvatică submersă prezintă o deviație standard foarte ridicată în banda 4, infraroșu apropiat. Totuși, în celelalte benzi deviația standard este mai mică, în schimb, diferențele dintre valorile medii ale claselor sunt mai mici.

Se mai poate observă că deviațiile standard ale zonei de interes definită pentru nori sunt ridicate în toate benzile, în schimb și valorile medii diferă cu mult de toate celelalte medii, ceea ce va permite o clasificare corectă a norilor.

Mai este de așteptat ca zonele cu apă limpede și cele cu apă cu turbiditate ridicată să nu fie clasificate corect, deoarece separabilitatea dintre cele două clase este scăzută, iar deviația standard pentru clasa de apă cu turbiditate ridicată este destul de mare în banda 2.

3.2.3.3 Evaluarea metodelor de clasificare supervizată

După definitivare definiției zonelor de interes au fost rulate proceduri de clasificare pentru zonele uscate și pentru cele acoperite de apă. Rezultatele pentru întreaga suprafață a deltei sunt prezentate în figurile 3.14 - 3.16.

Prin simplă observație vizuală se constată că există diferențe destul de mari între hărțile rezultate. În cazul metodei unghiului spectral se observă că există și zone care au rămas neclasificate, deși valoarea maximă a unghiului a fost modificată de la 0,1 radiani la 0,15 radiani pentru toate clasele cu excepția norilor. Au fost încercate și valori mai mari de 0,15, dar rezultatele nu au fost satisfăcătoare. În privința clasei de interes pentru această lucrare, există variații mari între suprafețele ariilor estimate prin cele trei metode.

Graficul din figura 3.13 reprezintă suprafețele ocupate de fiecare clasă în parte obținute prin utilizarea celor trei metode, iar tabelul 3.3 conține date cu privire la acuratețea globală a rezultatelor clasificării. Se poate observa faptul că există variații destul de mari în estimările suprafețelor acoperite de vegetație acvatică submersă.




Fig. 3.13 - Suprafețe ocupate de clasele obținute prin diferite metode de clasificare

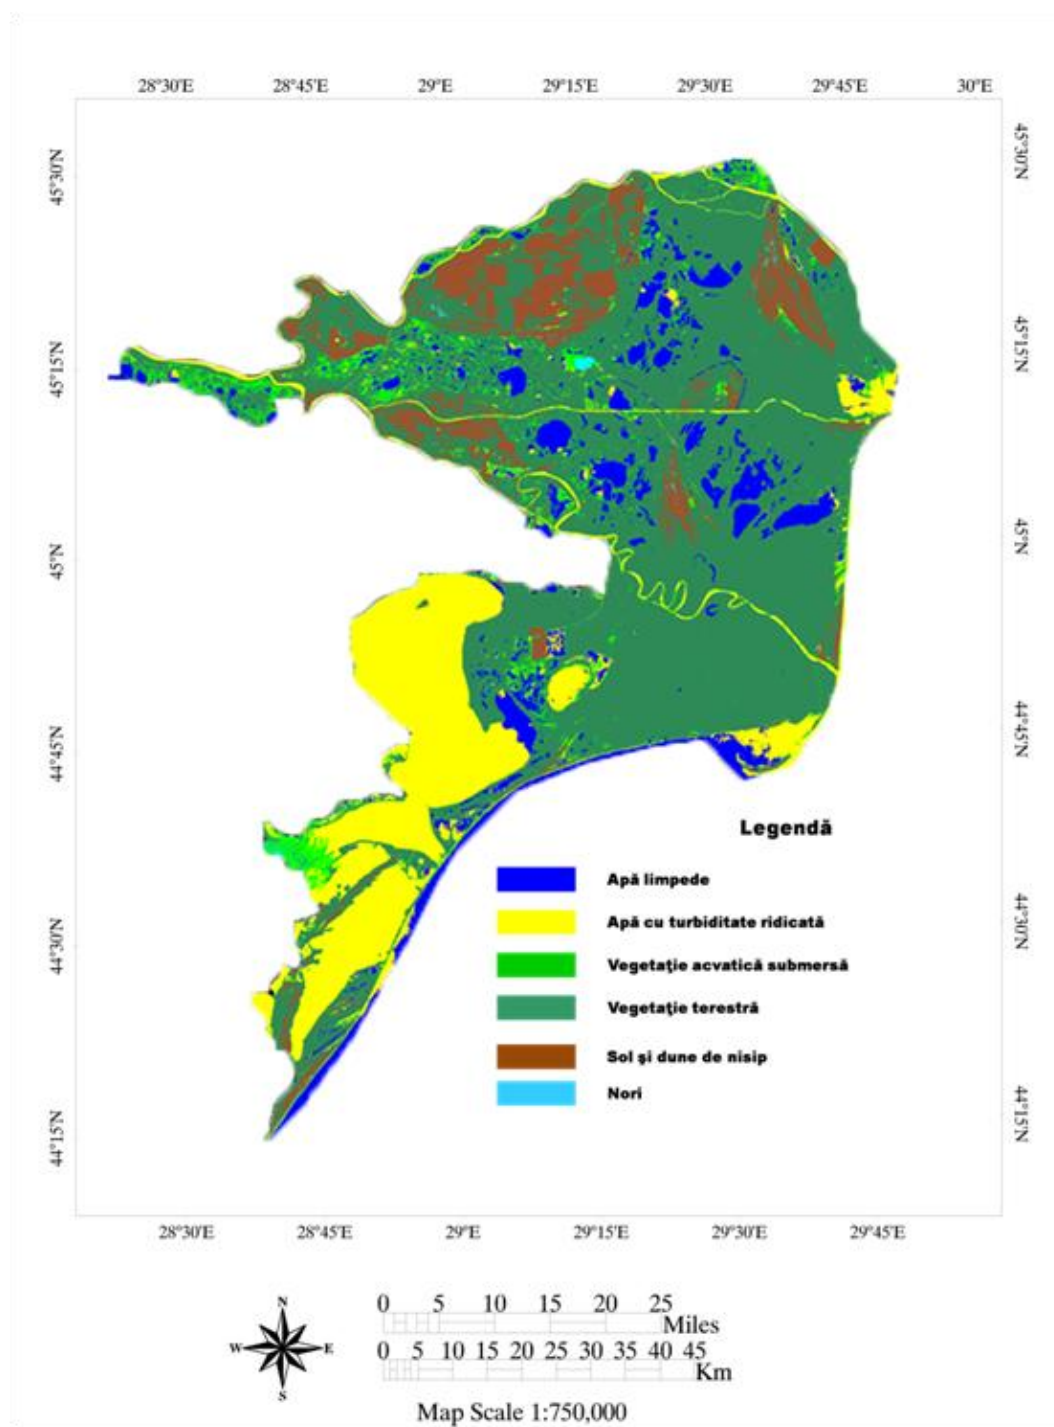


Fig. 3.14 - Clasificare prin metoda distanței minime (Minimum Distance)

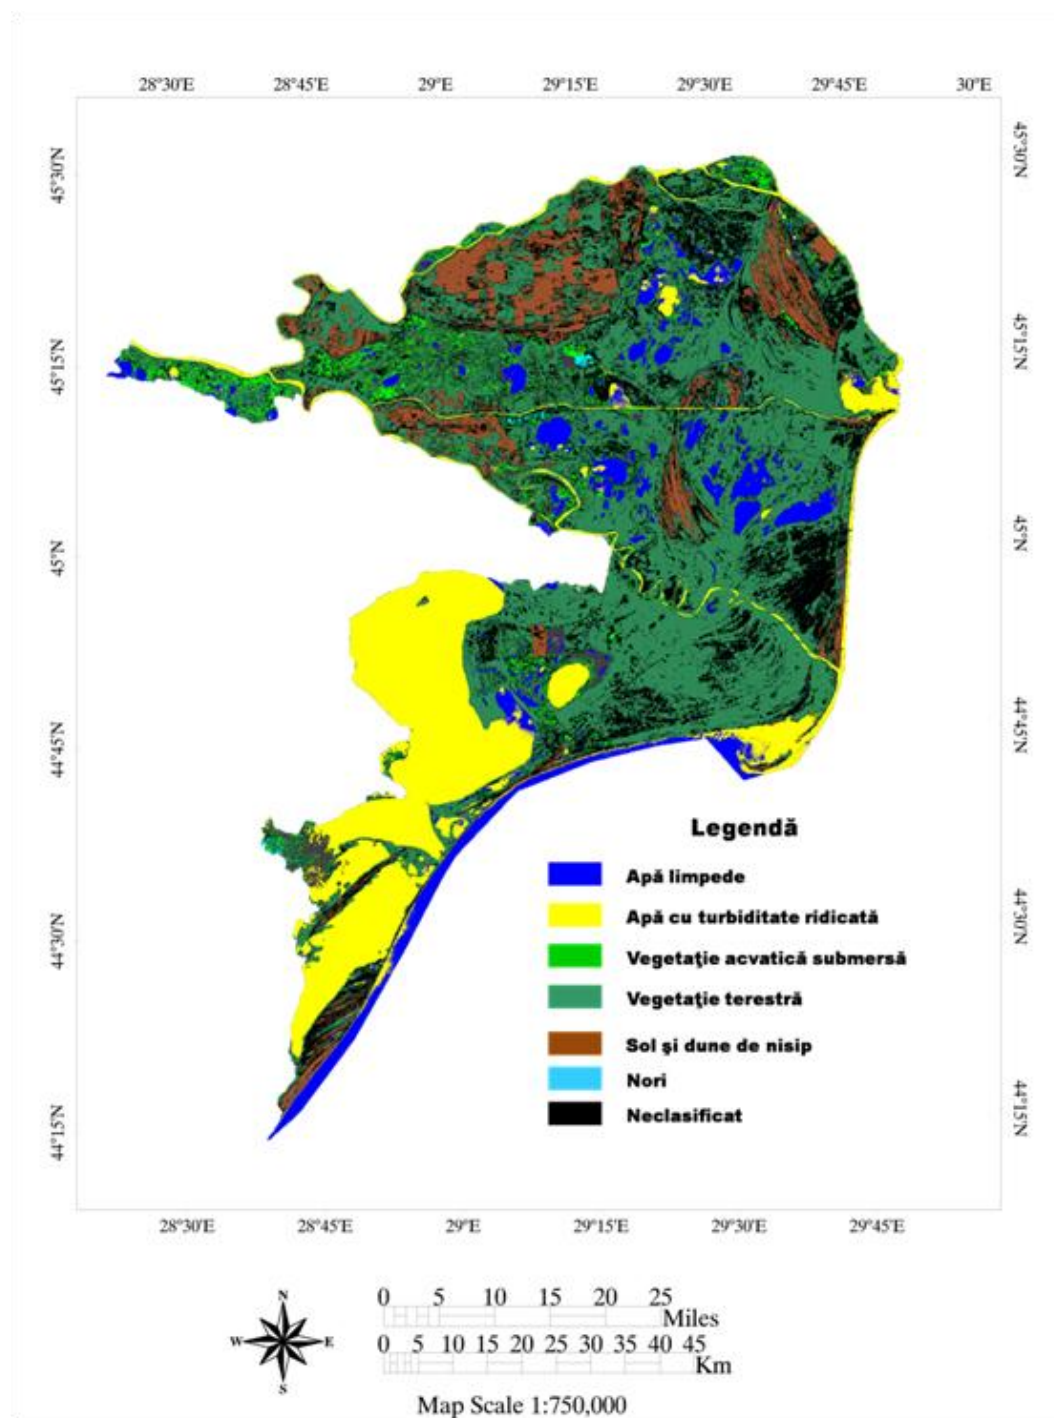


Fig. 3.15- Clasificare prin metoda unghiului spectral (Spectral Angle Mapper)

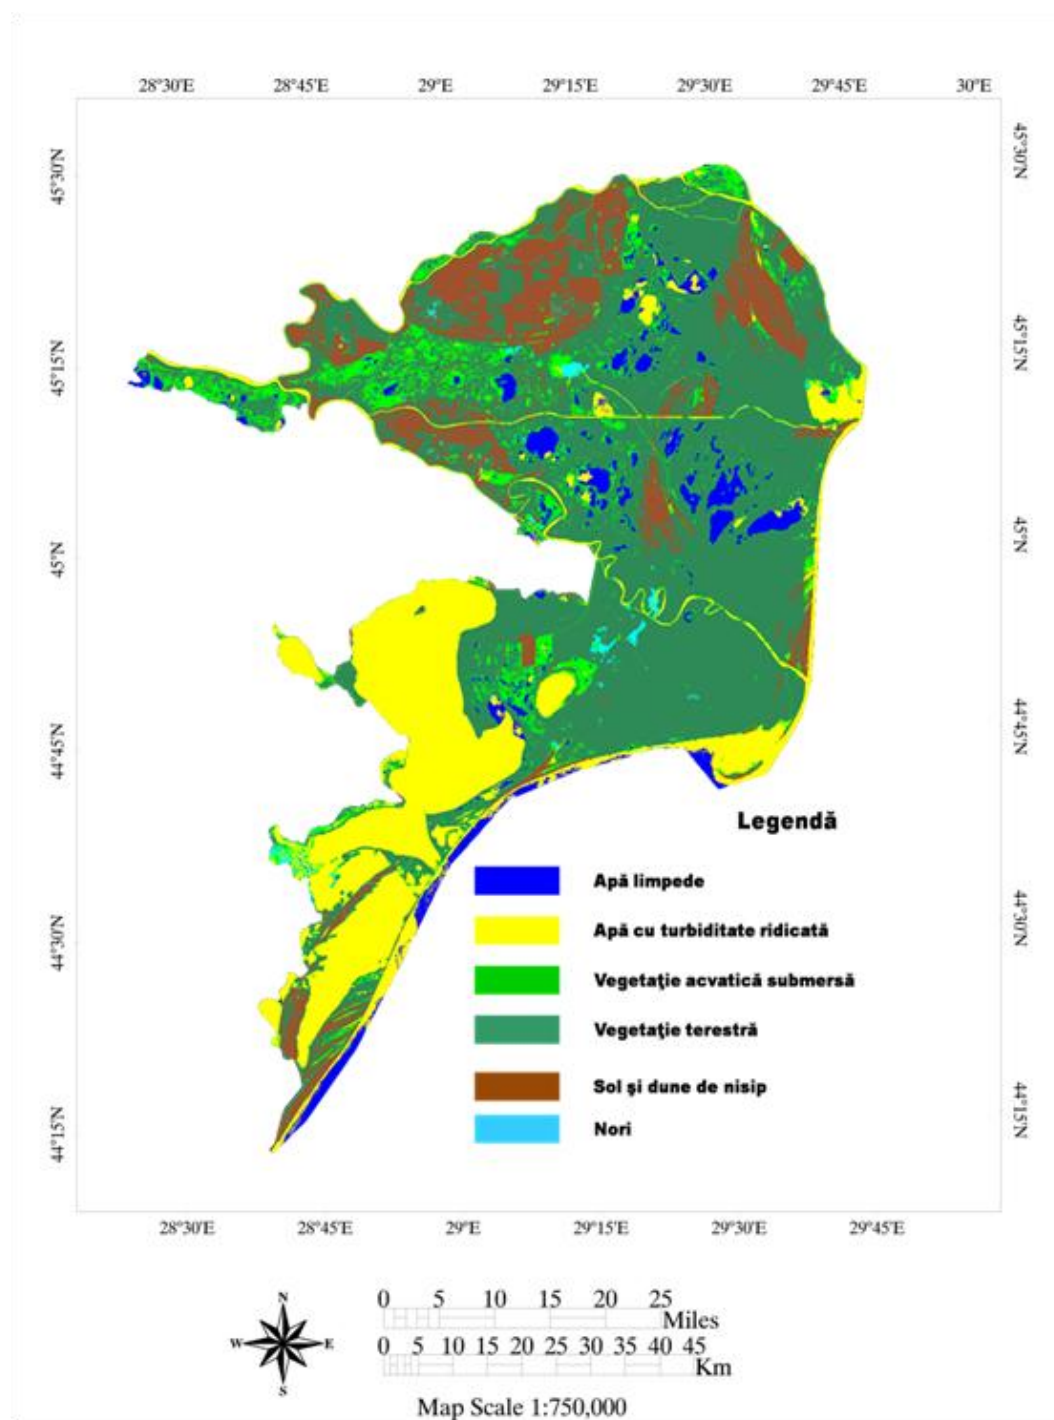


Fig. 3.16 - Clasificare prin metoda rețelelor neuronale artificiale (ANN)

Tabelul 3.3 - Acuratețea globală și coeficientul kappa pentru metodele de clasificare utilizate

Metodă de clasificare	Acuratețe globala (%)	Coeficientul kappa
Distanța minimă	77,41	0,47
Unghi spectral	71,09	0,44
Rețele neuronale	71,60	0,51

Din evaluarea statisticilor globale metoda distanței minime pare a fi cea mai precisă. O analiză mai complexă poate fi făcută utilizând matricea de confuzie prezentată în tabelul 3.4.

Tabelul 3.4 - Matricea de confuzie pentru clasificarea prin metoda distanței minime

Clase rezultate	Date de referință				
	Vegetație acvatică	Apă limpede	Apă cu turbiditate ridicată	Vegetație terestră	Total
Vegetație acvatică	58,65	9,25	1,47	4,84	11,3
Apă limpede	17,17	85,15	63,02	1,94	73,43
Apă cu turbiditate ridicată	12,73	2,79	35,45	0,81	7,52
Vegetație terestră	11,45	2,61	0,07	92,01	7,59
Total	100	100	100	100	100

Se poate observa faptul că cele două clase de apă au fost estimate cu precizia cea mai ridicată. În privința vegetației acvatice submerse au fost clasificați corect 58,65 % din pixelii de pe imaginea de referință. Restul au fost atribuiți în mod greșit altor clase, cei mai mulți dintre ei fiind clasificați ca apă limpede. Acest lucru se poate explica datorită faptului că în anumite zone comunitățile de vegetație acvatică au o densitate mică, iar multe dintre plante nu ajung la suprafața apei.

Se mai poate observa faptul că 12% din pixeli au fost clasificați greșit, ca vegetație terestră. Acest lucru poate fi pus pe seama faptului că masca folosită pentru delimitarea zonelor acoperite de apă nu a putut fi realizată cu o precizie ridicată. Zonele de delimitare între lacuri și uscat pot fi greu de estimat, mai ales atunci când lângă mal există comunități de vegetație acvatică cu densitate foarte mare.

În anexa 2 se găsesc toate matricile de confuzie, precum și tabele care cuprind preciziile de estimare și de interpretare și erorile de includere și de omisiune.

3.3 Preprocesarea imaginilor Landsat 8

3.3.1 Crearea mozaicului și tăierea imaginii

Cele două imagini Landsat 8, orbita 181, rândurile 28 și 29, înregistrate pe 24 Mai 2015, au fost folosite pentru crearea mozaicului prin metoda imaginilor georeferențiate. Sistemul de proiecție geografică folosit a fost UTM, Zona 35N, Datum WGS-84. După obținerea mozaicului, imaginea a fost tăiată după vectorul creat manual pentru delimitarea Deltei Dunării. Rezultatul se poate vizualiza în figură 3.17. Se poate observa că această imagine este acoperită de mai mulți nori, ceea ce a reprezentat o provocare în plus pentru procesarea ei.



Fig. 3.17 - Delta Dunării - imagine Lansat 8 tăiata conform limitelor stabilite

În cazul acestei imagini nu a mai fost suficientă calcularea indicilor NDWI și MNDWI pentru crearea măștii pentru zonele acoperite de apă datorită prezenței norilor. O parte din umbrele acestora au fost incluse în zonele acoperite de apă prin simpla folosire a celor doi indici. Din acest motiv au fost calculați trei indici suplimentari: I_1 , I_2 și I_3 .

În figură 3.18 se pot vedea două secțiuni ale imaginii din zone acoperite de nori, una în combinație RGB, iar cealaltă, din aceeași zonă în reprezentare tonuri de gri pentru indicele I_1 . Se poate observa că efectul umbrelor norilor este puternic atenuat în reprezentarea corespunzătoare indicelui.




Fig. 3.18 - Reprezentare a unei zone acoperite de nori în combinație RGB (stânga) și în reprezentare în tonuri de gri pentru indicele I_1 (dreapta)

Au fost create 3 măști, una pentru zonele acoperite de apă, iar celelalte pentru mascarea zonelor umbrite de nori. Mască pentru apă a fost creată folosind indicele MNDWI, pentru valori pozitive pentru numărul digital asociat pixelilor. Ca și în cazul imaginii Landsat 7, a fost necesară corectarea manuală a măștii rezultate pentru aria de studiu pentru completarea zonelor acoperite de apă, dar neincluse în zona mascată. În plus, această mască include și zone umbrite de nori. S-au obținut 1.774.489 pixeli pentru care valoarea indicelui MNDWI este mai mare decât 0.

Pentru eliminarea zonelor umbrite de nori din masca zonelor acoperite de apă au fost create măști suplimentare folosind indicii I_1 , I_2 și I_3 .

Au fost folosite anumite transecte alese în zone potrivite pentru stabilirea valorilor benzilor corespunzătoare indicilor calculați. Prima mască a fost creată folosind banda corespunzătoare indicelui I_3 , pentru valori cuprinse între 2,4 și 3,3. Această mască conține zonele cu umbre de nori, dar și zone din vecinătatea apelor. Cea de-a doua mască a fost creată folosind indicele I_2 , pentru valori mai mari de 0,2 și conține zonele cu apă limpede precum și zonele umbrite de nori. Intersecția celor două măști reprezintă zonele umbrite de nori. S-au obținut 79.953 pixeli, din care 74.020 pixeli sunt situați în zonele acoperite de apă, conform primei măști.

Din prima mască s-au extras pixelii rezultați în urma intersecției ultimelor două măști și a rezultat o micșorare a suprafeței acoperite de apă cu 4,2 %.

3.3.2 Analiza componentelor principale

Ca și în cazul imaginii Landsat 7 s-a observat că doar primele 3 componente contribuie în mod semnificativ la diferențierea elementelor din imagine. Valorile Eigen, precum și valorile minime, maxime, medii și deviațiile standard ale fiecărei componente sunt prezentate în figurile 3.19 și 3.20. Tabelul 3.5 conține datele statistice rezultate.




Fig. 3.19 - Valorile Eigen rezultate în urma analizei componențelor principale pentru imaginea Landsat 8




Fig. 3.20 - Valorile minime, maxime (rosu), medii (alb) și deviațiile standard (verde) pentru componentele principale pentru imaginea Landsat 8

Tabelul 3.5 - Date statistice rezultate în urma analizei componentelor principale pentru imaginea Landsat 8

Basic Stats	Min	Max	Mean	Stdev	Num	Eigenvalue
Band 1	-43.1344	457.0359	0	58.79378	1	3456.708889
Band 2	-87.0724	130.2284	0	17.48951	2	305.882894
Band 3	-225.666	47.28668	0	9.702744	3	94.143236
Band 4	-26.5487	65.98637	0	2.082822	4	4.338146
Band 5	-24.6838	40.12893	0	1.563138	5	2.443402
Band 6	-44.0615	42.15698	0	1.186346	6	1.407418

În urma analizei s-a decis excluderea benzii 9 , Cirrus, din procesul de clasificare supervizată.

3.3.3 Clasificarea imaginilor

3.3.3.1 Definirea zonelor de interes

Zonele de interes au fost stabilite parcurgând aceleași etape ca în cazul imaginii Landsat 7. Zonele în care a fost observată prezența vegetației acvatice submerse au fost clasificate nesupervizat, prin metoda ISODATA, cu un număr minim de 5 clase și maxim de 20 de clase. În urma a 50 de iterații au rezultat 16 clase care au fost regrupate în patru clase mai mari. Din acestea au fost reținute doar trei pentru stabilirea zonei de interes pentru vegetație acvatică submersă. Celelalte zone de interes au fost stabilite prin identificare vizuală.

Pentru imaginea Landsat 8 a fost necesară introducerea unei clase suplimentare. Au rezultat în total șapte clase: apă limpede, apă cu turbiditate ridicată, vegetație acvatică submersă și nori pentru zonele acoperite de apă, iar pentru zonele de uscat au fost definite zonele sol și dune, vegetație terestră (cuprinde toate zonele de vegetație de pe uscat, inclusiv păduri),nori și umbre nori.

3.3.3.2 Analiza separabilității

Analiza separabilității s-a făcut în mod similar celei pentru imaginea Landsat 7. Figurile 3.21 și 3.22 prezintă graficele cu valorii medii și deviațiile standard ale zonelor de interes în funcție de cele 7 benzi folosite pentru clasificare.




Fig. 3.21 - Valori medii ale zonelor de interes în funcție de bandă pentru imaginea Landsat 8




Fig. 3.22 - Deviații standard ale zonelor de interes în funcție de bandă pentru imaginea Landsat

Se pot observa similitudini în privința răspunsului spectral pentru clasele umbre nori, vegetație acvatică submersă și vegetație terestră. Acest lucru se explică prin faptul că aproape toate speciile de vegetație se află într-un stadiu incipient de dezvoltare și prezintă reflectanță ridicată în spectrul benzii verde. Umbrele de nori au un răspuns similar claselor de vegetație deoarece majoritatea se situează în zone acoperite de plante.

Se poate observa că zonă de interes pentru sol și dune de nisip prezintă o deviație standard foarte ridicată în benzile din domeniu infraroșu. Este de așteptat să apară erori semnificative în clasificarea acestei clase însă acest aspect nu constituie scopul acestei lucrări.

3.3.3.3 Evaluarea metodelor de clasificare supervizată

Rezultatele clasificării supervizate pentru întreaga suprafață a deltei sunt prezentate în figurile 3.23 - 3.27.

Și în cazul procesării imaginii Landsat 7 se observă că există diferențe mari între hărțile rezultate. Acest lucru era de așteptat deoarece au fost folosite mai multe metode de clasificare, iar imaginea conține mai mult zgomot. Prezența norilor pe imagine, mai ales a celor din zona din care s-au extras zonele de interes pentru clasa vegetației acvatice submerse, introduce un factor de incertitudine suplimentar.

Așa cum era de așteptat din analiza separabilității zonelor de interes există erori mari în detectarea claselor nori și sol și dune de nisip. În urma evaluării vizuale s-a constatat că cele mai mari erori au apărut în cazul metodelor rețelelor neuronale artificiale și a unghiului spectral. Cea mai bună estimare pentru aceste clase a fost obținută în cazul metodei probabilității maxime în schimb această metodă a avut rezultate slabe pentru estimarea zonelor de vegetație acvatică submersă.

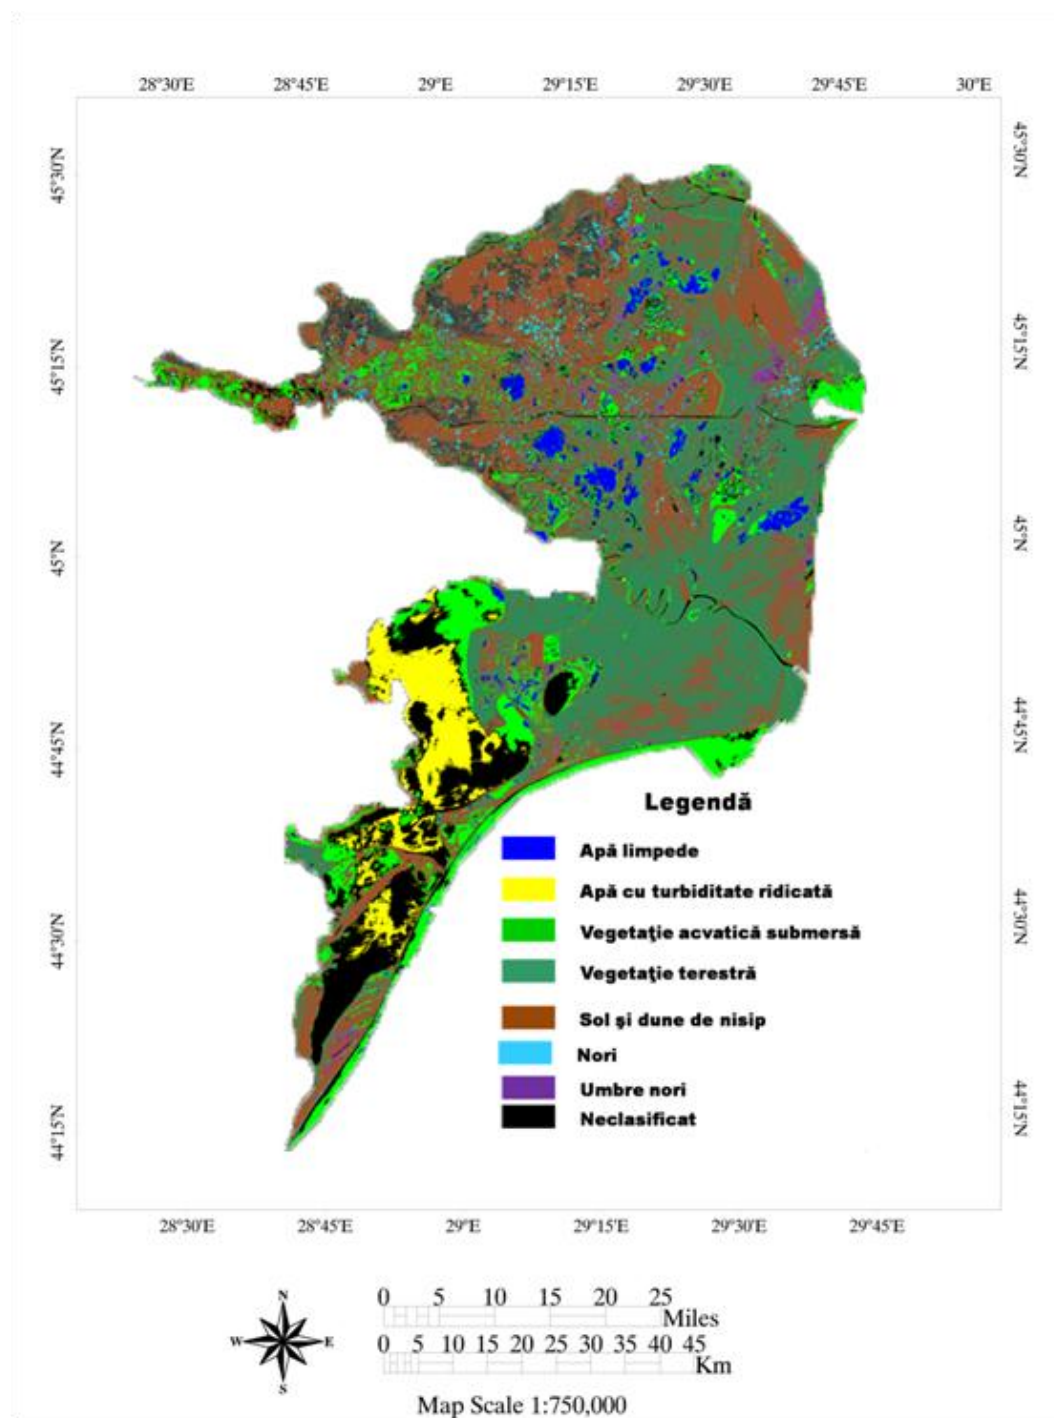


Fig. 3.23 - Clasificare prin metoda paralelipiped

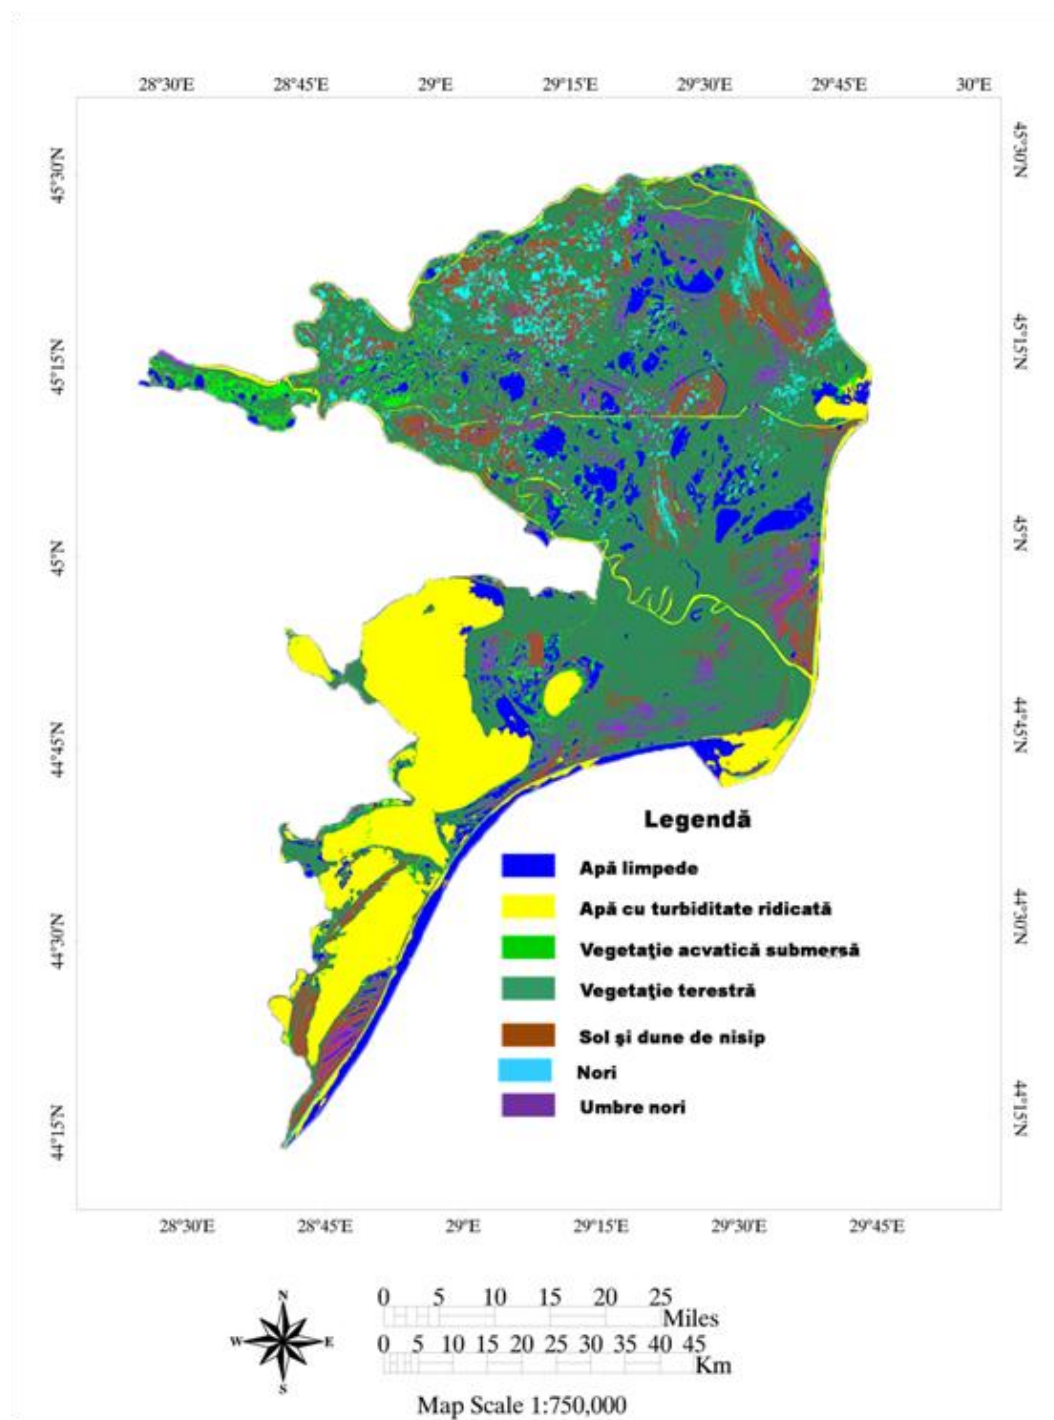


Fig. 3.24 - Clasificare prin metoda distanței minime

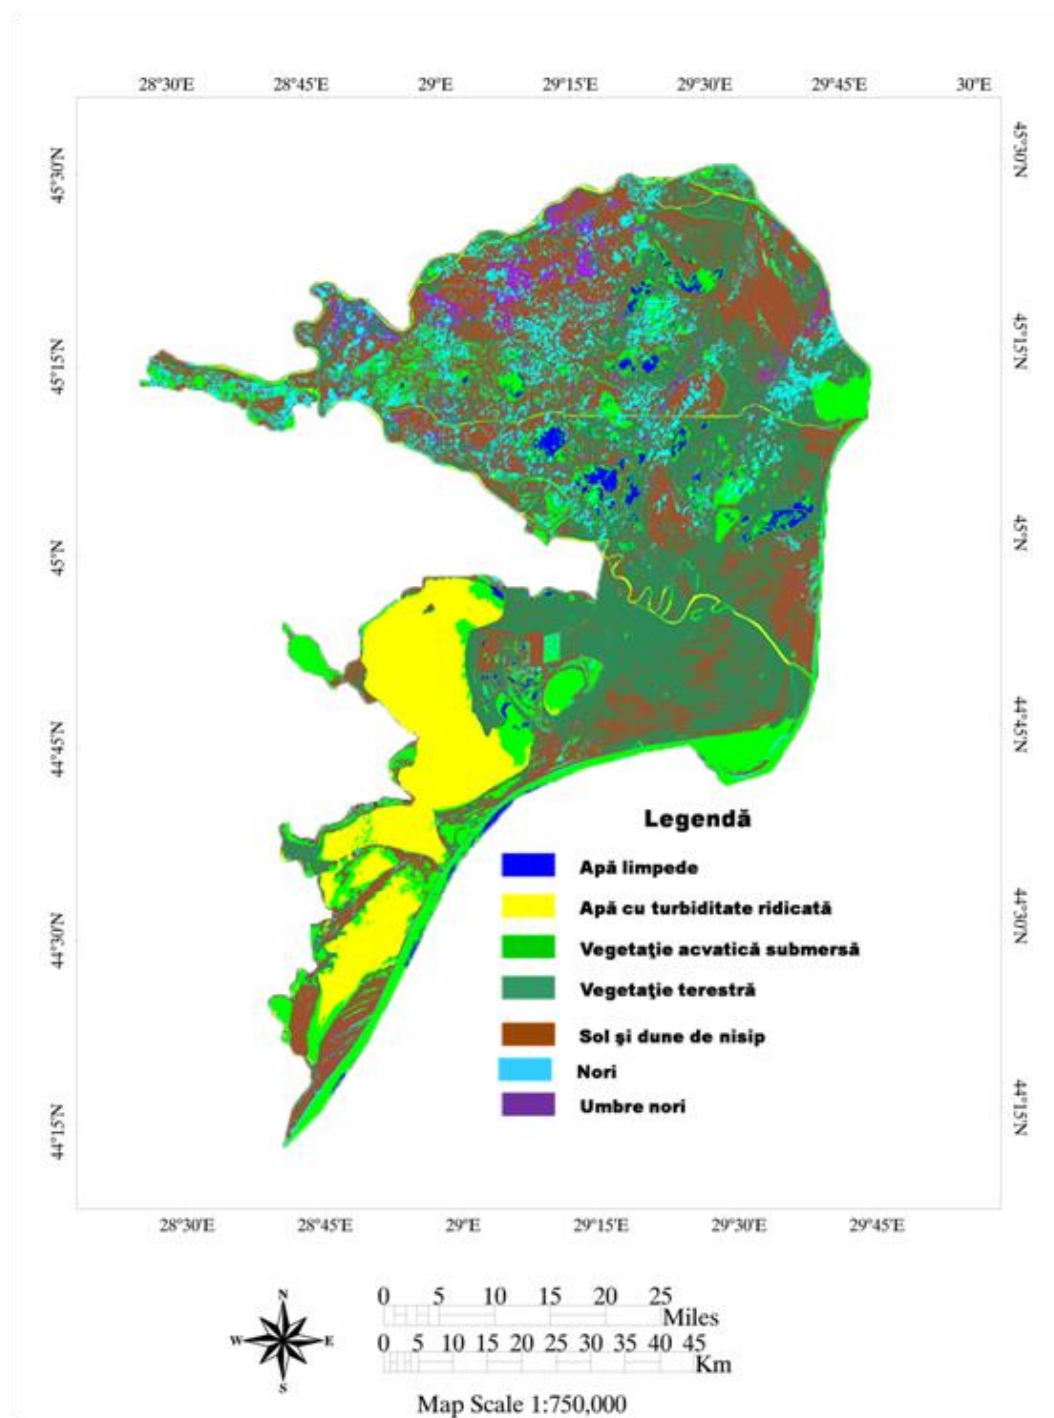


Fig. 3.25 - Clasificare prin metoda probabilității maxime

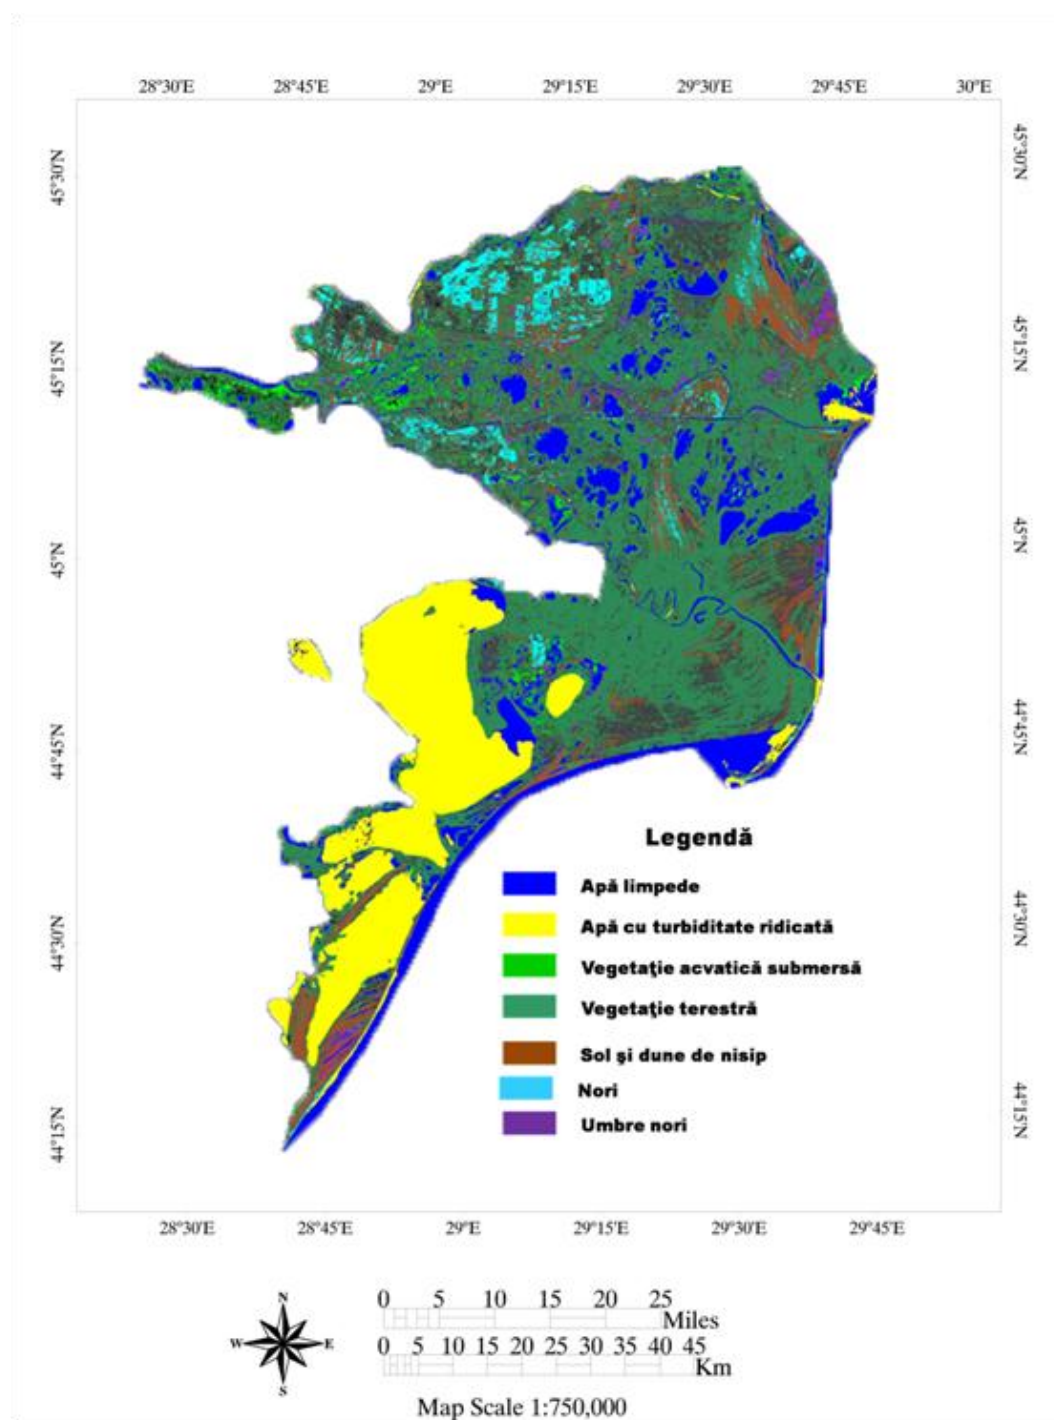


Fig. 3.26 - Clasificare prin metoda unghiului spectral

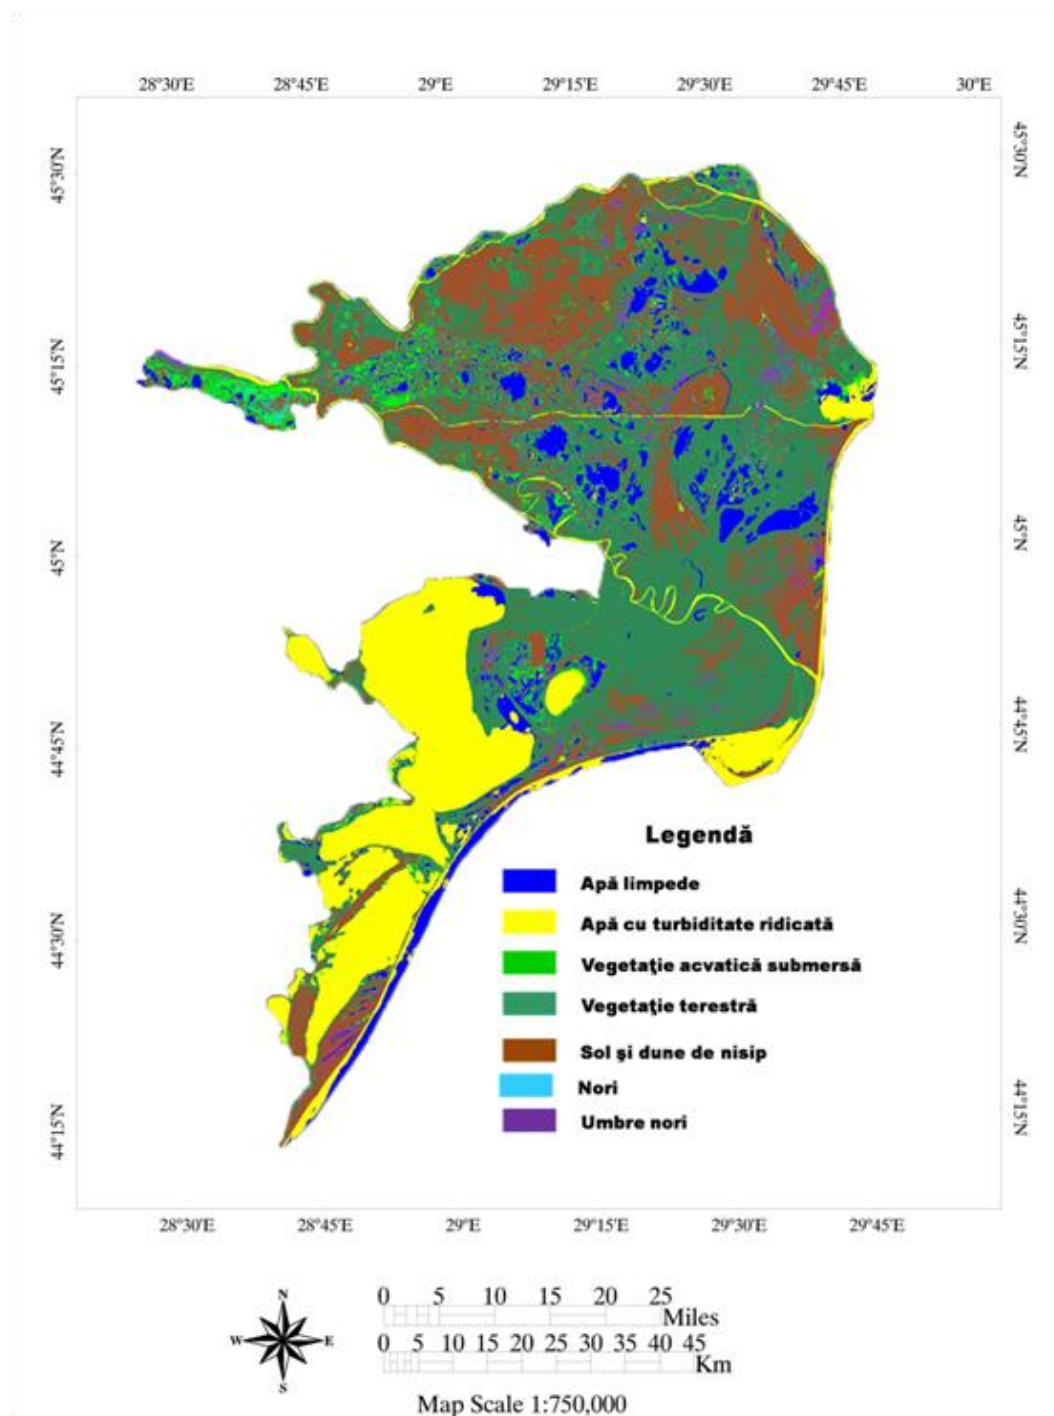


Fig. 3.27 - Clasificare prin metoda rețelelor neuronale artificiale

Graficul din figura 3.28 reprezintă suprafețele ocupate de fiecare clasă în parte obținute prin utilizarea celor trei metode, iar tabelul 3.6 conține date cu privire la acurțetea globală a rezultatelor clasificării.




Fig. 3.28 - Suprafețele ocupate de fiecare clasă pentru metodele de clasificare utilizate

Tabelul 3.6 - Acuratețea globală și coeficientul kappa pentru metodele de clasificare utilizate pentru imaginea Landsat 8

Clasificare	Acuratețe globala (%)	Coeficientul kappa
Paralelipiped	75,59	0,29
Distanță minimă	83,30	0,46
Probabilitate maximă	60,33	0,21
Unghi spectral	86,47	0,46
Rețele neuronale	85,27	0,47

Metodele distanței minime, a unghiului spectral și a rețelelor neuronale prezintă cea mai bună acuratețe generală. În cazul distanței minime și a unghiului spectral acest lucru se

explică prin faptul că aria de evaluare a preciziei este mult mai mică și prezintă doar o mică parte din caracteristicile generale ale imaginii. Mătricile de confuzie, datele despre erorile de omisiune și de includere, precizia de interpretare și de estimare sunt prezentate în anexa 2. Este foarte greu de decis care dintre metodele de clasificare ar fi cea mai potrivită pentru evaluarea vegetației acvatice deoarece imaginea folosită prezintă un grad ridicat de neomogenitate datorită prezenței noilor, iar zona aleasă pentru evaluarea rezultatelor este foarte restrânsă. În urma analizei erorilor de includere și de omisiune precum și în urma evaluării vizuale s-ar putea decide, ca și în cazul imaginii Landsat 7, că cea mai potrivită metodă este cea a distanței minime.

3.4 Comparație între rezultatele obținute în urma procesării celor două imagini

Fiecare dintre imaginile Landsat 7 și 8 prezintă avantaje și dezavantaje în privința posibilității utilizării lor pentru clasificarea prin metode supervizate. Imaginea Landsat 7 este mai puțin acoperită de nori, dar prezintă goluri către marginile cadrelor datorită unei defecțiuni ale senzorului survenită în anul 2003. Aceste goluri au fost umplute prin metoda interpolării, iar această metodă introduce un factor de incertitudine suplimentar. Imaginea Landsat 8, deși conține mai multe benzi și are o rezoluție radiometrică mult mai bună, este acoperită de nori. Dacă s-ar fi folosit limita inferioară de 5245 a numărului digital al pixelilor în banda 9, Cirrus, pentru mascarea norilor (Kong et al. 2013) ar fi rezultat o suprafață acoperită de nori de 14%. Prezența norilor și lipsa omogenității imaginii din această cauză face ca rezultatul evaluării acurateții să fie foarte relativ. Pentru o evaluare mai precisă ar fi fost nevoie de o arie de control mult mai întinsă și de cunoștințe detaliate despre situația reală din teren.

Metoda de clasificare paralelipiped este cea mai puțin precisă, ceea ce era de așteptat datorită neomogenității imaginii. Pentru ca această metodă să funcționeze bine ar fi nevoie

ca elementele claselor definite să fie foarte bine separate în domeniul spectral. Metoda probabilitatii maxime ar putea returna rezultate mai precise în cazul folosiri unor regiuni de interes întinse pe suprafețe cât mai mari și care să prezinte caracteristici spectrale reprezentative pentru clasele definite (Richards, 2012). Metodele distanței minime și a unghiului spectral sunt cele mai potrivite atunci când se folosesc zone de interes limitate sau prezintă o variabilitate ridicată (Richards, 2012).

Graficul din figura 3.26 ilustrează preciziile de estimare și de interpretare pentru fiecare metodă folosită pentru clasificarea celor două imagini. Precizia de estimare reprezintă procentul din suprafața reală aparținând anumitei clase care a fost clasificată corect, iar precizia de interpretare reprezintă procentul suprafeței unei clase corect estimate.




Fig. 3.29 - Preciziile de estimare și de interpretare corespunzătoare clasei vegetație acvatică submersă pentru diverse metode de clasificare

O precizie de estimare ridicată indică faptul că o mare parte din suprafața reală din teren a fost inclusă în clasa corespunzătoare în urma clasificării, dar poate omite faptul că pe lângă suprafețele corespunzătoare clasei respective, clasificatorul poate include și suprafețe care ar trebui să aparțină altor clase. Acest fenomen se poate observa în cazul clasificării prin metoda probabilității maxime unde clasa de vegetație acvatică include cea mai mare parte a suprafețelor reale din aria de control, dar include și multe alte suprafețe cum ar fi linia țărmului Mării Negre sau Golful Musura.

Pentru situațiile studiate în această lucrare cele mai bune metode de clasificare au fost metoda distanței minime și metoda unghiului spectral, ambele cu o acuratețe mai ridicată în cazul imaginii Landsat 7. La nivel global, metoda rețelelor neuronale artificiale a prezentat performanțele cele mai ridicate. Totuși, această metodă prezintă o precizie de interpretare scăzută pentru clasa vegetație acvatică submersă, ceea ce înseamnă că doar unei mici părți din această clasă îi corespund în teren suprafețe reale. Această metodă supraestimează suprafețele corespunzătoare acestei clase.

Sumarizând, rezultatele metodelor de clasificare folosite sunt modeste, coeficientul kappa nu depășește valoare 0.5 decât în cazul metodei rețelelor neuronale pentru imaginea Landsat 7.

CAPITOLUL 4

CONCLUZII

În această lucrare s-a evaluat aplicabilitatea datelor din imaginile obținute de senzorii Landsat 7 și 8 pentru estimarea zonelor de dezvoltare a comunităților de plante acvatice din Delta Dunării.

Analiza răspunsului spectral al acestui tip de strat, comparată cu celelalte tipuri de vegetație, a permis observarea unei diferențieri în regiunile spectrale verde și infraroșu. Aceste diferențe apar datorită efectului de atenuare a radiației reflectate de plante de către substratul acvatic. Totuși, datorită stadiului incipient de dezvoltare a vegetației de la sfârșitul lunii mai deosebirile spectrale dintre vegetația acvatică și cea terestră sunt mai scăzute. Pe o imagine achiziționată pe 29 iunie 2014 s-au putut observa diferențe semnificative între răspunsul spectral al vegetației terestre și al celei acvatice. Acest lucru se poate explica de faptul că la acea dată comunitățile de vegetație prezentau un grad de maturizare mai accentuat, unele specii, cum ar fi stuful, având un răspuns spectral cu mult diferit față de cel de la sfârșitul lunii mai.

Pentru o mai bună separare a tipurilor de vegetație au fost rulate procese de preclasificare pentru crearea unei măști care să delimiteze zonele acoperite de apă de zonele de uscat. Datorită prezenței norilor în imaginea Landsat 8 din 24 Mai 2015 a fost necesară rularea unor proceduri suplimentare de corecție a imaginii. Utilizând procedurile consacrate pentru determinarea zonelor acoperite de apă, cum ar fi indicii NDWI, MNDWI, nu s-au obținut rezultate satisfăcătoare datorită interferenței norilor și a umbrelor acestora. Deasemenea, prezența norilor în aria de studiu, chiar în vecinătatea regiunii de unde s-au colectat date pentru definirea zonelor de interes pentru clasificarea supervizată a introdus un factor suplimentar de incertitudine.

Imaginea Landsat 7 din 1 iunie 2015 a fost lipsită de nori, dar a prezentat dezavantajul existenței golurilor către marginile cadrelor. A fost necesară rularea unui procedeu de interpolare pentru umplerea acestora.

Rezultatele proceselor de clasificare prezintă o dispersie considerabilă datorită dimensiunilor reduse ale zonelor de interes definite și a lipsei de reprezentativitate ale acestora pentru anumite clase.

Pentru evaluarea acurateții rezultatelor s-au folosit date din teren de pe o regiune limitată, datorită accesibilității limitate din Delta Dunării. Această regiune nu a cuprins zone care să poată fi atribuite tuturor claselor definite pentru clasificarea imaginilor, în schimb a conținut toate zonele din care s-au definit clase asociate ariilor acoperite de apă. Acest aspect a făcut ca rezultatele evaluării acurateții clasificării să nu fie reprezentative pentru întreaga imagine, în schimb aceste rezultate au fost folosite pentru evaluarea zonelor acoperite de apă.

Se poate spune că rezultatele obținute sunt modeste, în schimb, această lucrare prezintă o metodă de studiu pentru dinamica vegetației acvatice prin mijloace de teledetecție, precum și o metodă de minimizare a efectelor produse de nori în imaginile satelitare utilizate pentru clasificarea vegetației acvatice.

Deasemenea, trebuie amintit faptul că imaginile Landsat nu sunt potrivite pentru diferențierea speciilor de vegetație, pentru aceasta fiind nevoie de imagini cu rezoluții geometrice și spectrale mult mai ridicate. În schimb, aceste imagini se pot folosi pentru estimarea zonelor în care sunt prezente comunități de vegetație acvatică.

În lucrări ulterioare, mărirea preciziei estimărilor realizate prin metode de teledetecție se poate obține prin utilizarea următoarelor proceduri:

1. Utilizarea unor imagini mai puțin contaminate de prezența norilor
2. Utilizarea unor imagini achiziționate în perioade în care vegetația prezintă un grad de maturizare mai ridicat
3. Implementarea unor metode de preprocesare mai elaborate pentru eliminarea efectelor nedorite datorate prezenței elementelor perturbatoare
4. Achiziționarea unei set de date din teren mai cuprinzător și din zone reprezentative pentru clasele definite pentru procesul de clasificare și care să permită o selecție mai bună a acestora pentru definirea zonelor de interes
5. Rularea unui număr mai mare de iterații și calibrarea metodelor de clasificare a imaginilor pe baza zonelor de interes definite
6. Utilizarea unor suprafețe mai mari pentru evaluarea acurateții rezultatelor obținute în urma clasificărilor
7. Integrarea mai multor date în procesul de clasificare, cum ar fi cunoștințe detaliate din teren cu privire la compoziția fizică și chimică a apelor din zona de studiu, date obținute prin modelări hidrologice pentru estimarea zonelor de acumulare a sedimentelor și nutrienților

BIBLIOGRAFIE

- Banu, A., and S. Buzeteanu. *Date Noi Asupra Proceselor Actuale Geomorfologică În Delta Dunarii, Cu Privire Specială Asupra Colmatărilor*, 1966.
- Banu, A., and S. Rudescu. *Delta Dunarii*. Editura Științifică, 1965.
- Bertman, D. *Study of Alluvial Dynamics on Seaside of the Danube Delta through the Luminescent Colours*, 1964.
- Bilyk, H. *Geobotanical Zoning of Ukrainian SSR*, 1977.
- Brando, V.E., J.M. Anstee, M. Wettle, A.G. Dekker, S.R. Phinn, and C. Roelfsema. "A Physics Based Retrieval and Quality Assessment of Bathymetry from Suboptimal Hyperspectral Data." *Remote Sensing Of Environment* 113, no. 4 (2009): 755–70.
- Campbell, J., and R. Wynne. *Introduction to Remote Sensing*. THE GUILFORD PRESS, 2011.
- Chambers, P. A. "Light and Nutrients in the Control of Aquatic Plant Community Structure. II. In Situ Observations." *Journal of Ecology* 75 (1987): 621–28.
- Ciraolo, G., E. Cox, G. La Loggia, and A. Maltese. "The Classification of Submerged Vegetation Using Hyperspectral MIVIS Data." *Annals of Geophysics* 49, no. 1 (2006): 287–94.
- Coops, H., J. Hanganu, M. Tudor, and W. Oosterberg. "Classification of Danube Delta Lakes Based on Aquatic Vegetation and Turbidity." *Hydrobiologia* 415 (1999): 187–91.
- Diaconu, C., and N. Iacov. *Danube Delta Hydrology Monography*, 1963.
- Findlay, S.E.G., W.C. Nieder, E.A. Blair, and D.T. Fischer. "Multi-Scale Controls on Water Quality Effects of Submerged Aquatic Vegetation in the Tidal Freshwater Hudson River." *Ecosystems* 9, no. 1 (2006): 84–96.
- Finkbeiner, M., B. Stevenson, and R. Seaman. "Guidance for Benthic Habitat Mapping: An Aerial Photographic Approach." U.S. NOAA Coastal Services Center, 2001.
http://coast.noaa.gov/digitalcoast/_pdf/bhmguide.pdf.
- Gâstescu, P. "Geography." In *Soils of the Romanian Danube Delta Biosphere Reserve, Munteanu I. (Ed.)*. Research Institute for Soil Science and Agrochemistry, Bucharest; Danube Delta Institute, Tulcea; Institute for Inland Water Management and Waste water Treatment/RIZA nota nr. 96.070, Lelystad, The Netherlands, 1996.

- Geerken, R., B. Zaitchik, and J. P. Evans. "Classifying Rangeland Vegetation Type and Fractional Cover of Semi-Arid and Arid Vegetation Covers from NDVI Time-Series." *International Journal of Remote Sensing* 26, no. 24 (2005): 5535–54.
- Giosan, L., S. Constantinescu, F. Filip, and B. Deng. "Maintenance of Large Deltas through Channelization: Nature vs. Humans in the Danube Delta." *Anthropocene* 11 (2013): 11.
- Govender, M., K. Chetty, and H. Bulcock. "A Review of Hyperspectral Remote Sensing and Its Application in Vegetation and Water Resource Studies." *Water SA* 33 (2009): 145–452.
- Hallahan, N., and C. Prepperneau. "Cloud Detection and Removal Techniques for Landsat 8 Imagery." Department of Geography, Oregon State University, 2013.
- Hanganu, J., I. Grigoraș, N. Ștefan, I. Sârbu, D. Dubyna, E. Zhmud, U. Menke, and H. Drost. *Vegetation of the Biosphere Reserve Danube Delta*. Danube Delta Technological Information Center, 2002.
- Hyun Jung, Cho, D. Mishra, and J. Wood. *Remote Sensing of Submerged Aquatic Vegetation, Remote Sensing - Applications, Dr. Boris Escalante (Ed.)*. InTech, 2012.
- Jackson, T. J., D. Chen, M. Cosh, F. Li, M. Anderson, C. Walthall, P. Doriaswamy, and E. R. Hunt. "Vegetation Water Content Mapping Using Landsat Data Derived Normalized Difference Water Index for Corn and Soybeans." *Remote Sensing Of Environment* 92, no. 3 (2004): 475–82.
- Janauer, G. A., and G. Kum. "Macrophytes and Floodplain Water Dynamics in the River Danube Ecotone Research Region (Austria)." *Hydrobiologia* 340 (1996): 137–40.
- Jensen, J. R. *Digital Image Processing: A Remote Sensing Perspective*. Prentice Hall PTR, 2000.
- Jin, X. *Technologies of Lake Eutrophication Control Management*. Beijing: Chemistry Industry Press, 2001.
- Jung, M, G Churkina, and K Henkel. "Exploiting Synergies of Global Land Cover Products for Carbon Cycle Modeling." *Remote Sensing of Environment* 101, no. 534 (n.d.): 53.
- Khan, M.A., Y.H. Fadlallah, and K.G. AL-Hinai. "Thematic Mapping of Subtidal Coastal Habitats in the Western Arabian Gulf Using Landsat TM Data - Abu Ali Bay, Saudi Arabia." *International Journal of Remote Sensing* 13, no. 4 (1992): 605–14.
- Lambin, EF, BL Turner, and J Helmut. "The Causes of Land-Use and Land-Cover Change: Moving beyond the Myths." *Global Environmental Change* 11 (2001): 261–69.

- Langley, SK, HM Cheshire, and KS Humes. "A Comparison of Single Date and Multitemporal Satellite Image Classifications in a Semi-Arid Grassland." *Journal of Arid Environments* 49 (n.d.): 401–11.
- Lathrop, R. G., P. Montesano, and S. Haag. "A Multi-Scale Segmentation Approach to Mapping Seagrass Habitats Using Airborne Digital Camera Imagery." *Photogrammetric Engineering and Remote Sensing (PHOTOGRAMM ENG REM S)* Publisher: American Society of Photogrammetry; American Society for Photogrammetry and Remote 72 (2006): 665–75.
- Lillesland, T., R. Kiefer, and J. Cihpman. *Remote Sensing and Image Interpretation*. Wiley & Sons., 2004.
- Li, P., L. Jiang, and Z. Feng. "Cross-Comparison of Vegetation Indices Derived from Landsat-7 Enhanced Thematic Mapper Plus (ETM+) and Landsat-8 Operational Land Imager (OLI) Sensors." *Remote Sensing* 6 (2014): 310–29.
- Matsunaga, T., and H. Kayanne. "Observation of Coral Reefs on Ishigaki Island, Japan, Using Landsat TM Images and Aerial Photographs." In *Proceedings of the Fourth International Conference on Remote Sensing for Marine and Coastal Environments*, I:657–66. Orlando, Florida, USA, 1997.
- Mihai, B.A. *Teledetecție. Introducere în procesarea digitală a imaginilor*. Ed. Universității din București, 2007
- Mishra, D., S. Narumalani, D. Rundquist, and M. Lawson. "Benthic Habitat Mapping in Tropical Marine Environments Using QuickBird Imagery." *Photogrammetric Engineering and Remote Sensing* 72, no. 9 (2006): 1037–48.
- Mishra, D., S. Narumalani, D. Rundquist, and M. Lawson. "High Resolution Ocean Color Remote Sensing of Benthic Habitats: A Case Study at the Roatan Island, Honduras." *IEEE Transactions in Geosciences and Remote Sensing* 43, no. 7 (2005): 1592–1604.
- Niculescu, S., C. Lardeux, I. Grigoraș, J. Hanganu, and L. David. "Synergy between LIDAR and RADARSAT-2 Images for the Recognition of Vegetation Structures in the Coastal Wetlands of the Danube Delta." Vienna, 2014.
- Nordberg, ML, and J Evertson. "Vegetation Index Differencing and Linear Regression for Change Detection in a Swedish Mountain Range Using Landsat TM and ETM+ Imagery." *Land Degradation & Development* 16 (2003): 139–49.
- Pasqualini, V., C. Pergent-Martini, G. Pergent, M. Agreil, G. Skoufas, L. Sourbes, and A. Tsirika. "Use of SPOT 5 for Mapping Seagrasses: An Application to Posidonia Oceanica." *Remote Sensing of Environment* 94, no. 1 (2005): 39–45.

- Petrescu, I. *Danube Delta. Origin and Development*. Foreign lit., 1963.
- Richards, J. *Remote Sensing Digital Image Analysis*. Springer, 2012.
- Rounsevell, M. D. A., I. Reginster, and M. B. Araujo. "A Coherent Set of Future Land Use Change Scenarios for Europe Agriculture." *Agriculture, Ecosystems & Environment* 114 (2006): 57–68.
- Rouse, J., R. Haas, J. Schell, and D. Deering. "Monitoring Vegetation Systems in the Great Plains with ERTS," 1973.
- Schowengerdt, R.A. *Remote Sensing: Models and Methods for Image Processing*. New York: Academic Press, 1997.
- Shvebs, G. *Nature of Odessa Region*, 1979.
- Spence, D. H. N. "The Zonation of Freshwater Plants." *Advances in Ecological Research* 12 (1982): 37–125.
- Van den Berg, M. S., H. Coops, M. L. Meijer, M. Scheffer, and J. Simons. ". Clear Water Associated with a Dense Chara Vegetation in the Shallow and Turbid Lake Veluwemeer, The Netherlands. In Jeppesen, E., M. Sondergaard, M. Sondergaard & K. Christoffersen (eds).," In *The Structuring Role of Submerged Macrophytes in Lakes*, 339–52. Springer, 1997.
- Van den Brink, F. W. B., M. M. J. Maenen, G. Van der Velde, and A. Bij de Vaate. "The (semi-) Aquatic Vegetation of Still Waters within the Floodplains of the Rivers Rhine and Meuse in The Netherlands: Historical Changes and the Role of Inundation." *Verhandlungen Des Internationalen Verein Limnologie* 24 (1991): 2693–99.
- Walters, B., P. Ronnback, J. Kovacs, B. Crona, S. Hussain, R. Badola, J. H. Primavera, E. Barbier, and F. Dahdouh-Guebas. "Ethnobiology, Socio-Economics and Adaptive Management of Mangroves: A Review." *Aquatic Botany* 89 (2008): 220–36.
- Wolter, P. T., C. A. Johnston, and G. Niemi. "Mapping Submergent Aquatic Vegetation in the US Great Lakes Using Quickbird Satellite Data." *International Journal of Remote Sensing* 26 (2005): 5255–74.
- Wu, C., Z. Niu, Q. Tang, and W. Huang. "Estimating Chlorophyll Content from Hyperspectral Vegetation Indices: Modeling and Validation." *Agricultural and Forest Meteorology* 48, no. 8–9 (2008): 1230–41.
- Xiangsheng, K., Q. Yonggang, and Z. Anding. "Cloud and Shadow Detection and Removal for Landsat-8 Data," 2013.

Xiao, XM, Q Zhang, and B Braswell. "Modeling Gross Primary Production of Temperate Deciduous Broadleaf Forest Using Satellite Images and Climate Data." *Remote Sensing of Environment* 91 (2004): 256–70.

Yichun, Xie, Sha Zongyao, and Yu Mei. "Remote Sensing Imagery in Vegetation Mapping: A Review Yichun Xie." *Journal of Plant Ecology* 1, no. 1 (March 2008): 9–23.

Zhu, Z., and C. Woodcock. "Object-Based Cloud and Cloud Shadow Detection in Landsat Imagery." *Remote Sensing of Environment* 118 (2012): 83–84.

<http://www-gvm.jrc.it/glc2000/>

<http://duckwater.bu.edu/lc/mod12q1.html>

<http://earthexplorer.usgs.gov/>

Anexa 1

Specii de vegetație acvatică submersă observate în aria de studiu



Foto A.1 - Potamogeton pectinatus și Trapa natans



Foto A.2 - *Potamogeton crispus*



Foto A.3 - *Nuphar luteum*



Foto A.4 - *Nymphaea alba*

Anexa 2

Date statistice obținute în urma proceselor de clasificare

Tabel A.2.1 - Suprafețele ocupate de diverse clase - imaginea Landsat 7 (km²)

Clasa	Apă limpede	Apă cu turbiditate ridicată	Vegetație acvatică submersă	Vegetație terestră	Sol și dune de nisip	Nori
Distanța minimă	431.78	921.69	250.74	2645.59	407.80	10.97
Unghi spectral	301.96	865.94	172.41	1750.69	342.81	21.27
Rețele neuronale	224.45	989.69	390.07	2431.64	598.20	34.53

Tabel A.2.2 - Suprafețele ocupate de diverse clase - imaginea Landsat 8 (km²)

Clasa	Apă limpede	Apă cu turbiditate ridicată	Vegetație acvatică submersă	Vegetație terestră	Sol și dune de nisip	Nori	Umbre nori
Paralelipiped	110.28	209.52	613.72	1221.31	1479.86	77.35	97.77
Distanța minimă	411.98	845.02	268.51	2090.14	574.80	181.80	296.32
Probabilitate maximă	79.29	570.51	735.05	1263.76	1427.74	454.09	138.13
Unghi spectral	564.51	695.13	228.08	1709.58	423.12	178.74	124.18
Rețele neuronale	352.95	908.40	263.32	1776.51	1166.84	42.65	157.88

Tabel A.2.3 - Matricea de confuzie pentru clasificarea prin metoda distanței minime - imaginea Landsat 7 (%)

Clase rezultate	Date de referinta				
	Vegetație acvatică	Apă limpede	Apă cu turbiditate ridicata	Vegetație terestră	Total
Vegetație acvatică	58.65	9.25	1.47	4.84	11.3
Apă limpede	17.17	85.15	63.02	1.94	73.43
Apă cu turbiditate ridicata	12.73	2.79	35.45	0.81	7.52
Vegetație terestră	11.45	2.61	0.07	92.01	7.59
Total	100	100	100	100	100

Tabel A.2.4 - Matricea de confuzie pentru clasificarea prin metoda rețelelor neuronale artificiale - imaginea Landsat 7 (%)

Clase rezultate	Date de referinta				
	Vegetație terestră	Vegetație acvatică	Apă limpede	Apă cu turbiditate ridicata	Total
Vegetație terestră	49.15	5.47	0.85	0	3.6
Vegetație acvatică	4.6	48.81	8.07	0.67	9.64
Apă limpede	0.16	7.91	75.86	28.01	61.25
Apă cu turbiditate ridicata	0	0.06	1.52	63.62	9.28
Total	100	100	100	100	100

Tabel A.2.5 - Matricea de confuzie pentru clasificarea prin metoda unghiului spectral- imaginea Landsat 7 (%)

Clase rezultate	Date de referinta				
	Vegetație terestră	Vegetație acvatică	Apă limpede	Apă cu turbiditate ridicata	Total
Vegetație terestră	88.14	7.4	2.42	0.07	6.97
Vegetație acvatică	7.43	83.22	22.55	6.34	23.7
Apă limpede	0.16	5.27	66.38	4.07	50.88
Apă cu turbiditate ridicata	0	0.06	8.27	89.53	17.67
Total	100	100	100	100	100

Tabel A.2.6 - Matricea de confuzie pentru clasificarea prin metoda paralelipiped - imaginea Landsat 8 (%)

Clase rezultate	Date de referinta				
	Vegetație terestră	Nori	Apă limpede	Vegetație acvatică	Total
Vegetație terestră	64.35	0	0.33	0.55	2.13
Nori	0	98.77	0.01	0	0.83
Apă limpede	0.91	0	76.79	23.41	71.54
Vegetație acvatică	34.73	1.23	22.87	76.04	25.5
Total	100	100	100	100	100

Tabel A.2.7 - Matricea de confuzie pentru clasificarea prin metoda distanței minime - imaginea Landsat 8 (%)

Clase rezultate	Date de referinta				
	Vegetație terestră	Nori	Apă limpede	Vegetație acvatică	Total
Vegetație terestră	78.76	0.89	2.04	14.73	6.26
Nori	0	60.71	0.01	0	0.94
Apă limpede	4.31	0.3	87.34	36.29	79.25
Vegetație acvatică	16.93	38.1	10.61	48.98	13.56
Total	100	100	100	100	100

Tabel A.2.8 - Matricea de confuzie pentru clasificarea prin metoda probabilității maxime - imaginea Landsat 8 (%)

Clase rezultate	Date de referinta				
	Vegetație terestră	Nori	Apă limpede	Vegetație acvatică	Total
Vegetație terestră	68.9	0.75	0.4	0.7	2.26
Nori	2.17	96.02	0.86	9.33	3.16
Apă limpede	0.18	0	58.1	7.02	52.94
Vegetație acvatică	28.75	3.23	40.64	82.95	41.64
Total	100	100	100	100	100

Tabel A.2.9 - Matricea de confuzie pentru clasificarea prin metoda unghiului spectral - imaginea Landsat 8 (%)

Clase rezultate	Date de referinta				
	Vegetație terestră	Nori	Apă limpede	Vegetație acvatică	Total
Vegetație terestră	77.82	0	1.38	15.15	5.19
Nori	0	40.55	0.03	0.09	0.58
Apă limpede	4.71	2.75	89.95	40.33	82.76
Vegetație acvatică	17.47	56.7	8.64	44.42	11.47
Total	100	100	100	100	100

Tabel A.2.10 - Matricea de confuzie pentru clasificarea prin metoda rețelelor neuronale artificiale - imaginea Landsat 8 (%)

Clase rezultate	Date de referinta				
	Vegetație terestră	Vegetație acvatică	Nori	Apă limpede	Total
Vegetație terestră	77.1	14.38	0	1.9	5.97
Vegetație acvatică	17.96	50.27	14.66	9.56	12.4
Nori	0.74	0.16	84.82	0.5	1.25
Apă limpede	4.2	35.19	0.52	88.03	80.39
Total	100	100	100	100	100

Tabel A.2.11 - Precizia de estimare si de interpretare pentru rezultatele clasificarii prin metoda distanței minime - imaginea Landsat 7

Clasa	Precizia de estimare	Precizia de interpretare	Precizia estimarii	Precizia de interpretare
	(procent)	(procent)	(pixeli)	(pixeli)
Vegetație acvatică	58.65	34.39	912/1555	912/2652
Apă limpede	85.15	87.35	15054/17679	15054/17235
Apă cu turbiditate ridicata	35.45	60.23	1063/2999	1063/1765
Vegetație terestră	92.01	63.97	1140/1239	1140/1782

Tabel A.2.12 - Precizia de estimare si de interpretare pentru rezultatele clasificarii prin metoda unghiului spectral - imaginea Landsat 7

Clasa	Precizia de estimare	Precizia de interpretare	Precizia estimarii	Precizia de interpretare
	(procent)	(procent)	(pixeli)	(pixeli)
Vegetație terestră	49.15	72.07	609/1239	609/845
Vegetație acvatică	48.81	33.55	759/1555	759/2262
Apă limpede	75.86	93.29	13411/17679	13411/14376
Apă cu turbiditate ridicata	63.62	87.6	1908/2999	1908/2178

Tabel A.2.13 - Precizia de estimare si de interpretare pentru rezultatele clasificarii prin metoda rețelelor neuronale artificiale - imaginea Landsat 7

Clasa	Precizia de estimare	Precizia de interpretare	Precizia estimarii	Precizia de interpretare
	(procent)	(procent)	(pixeli)	(pixeli)
Vegetație terestră	88.14	66.71	1092/1239	1092/1637
Vegetație acvatică	83.22	23.27	1294/1555	1294/5562
Apă limpede	66.38	98.27	11736/17679	11736/11942
Apă cu turbiditate ridicata	89.53	64.73	2685/2999	2685/4148

Tabel A.2.14 - Precizia de estimare si de interpretare pentru rezultatele clasificarii prin metoda paralelipiped -imaginea Landsat 8

Clasa	Precizia de estimare	Precizia de interpretare	Precizia estimarii	Precizia de interpretare
	(procent)	(procent)	(pixeli)	(pixeli)
Vegetație terestră	64.35	84.41	352/547	352/417
Nori	98.77	98.77	160/162	160/162
Apă limpede	76.79	98.44	13783/17950	13783/14002
Vegetație acvatică	76.04	13.92	695/914	695/4992

Tabel A.2.15 - Precizia de estimare si de interpretare pentru rezultatele clasificarii prin metoda distanței minime - imaginea Landsat 8

Clasa	Precizia de estimare	Precizia de interpretare	Precizia estimarii	Precizia de interpretare
	(procent)	(procent)	(pixeli)	(pixeli)
Vegetație terestră	78.76	57.33	786/998	786/1371
Nori	60.71	99.03	204/336	204/206
Apă limpede	87.34	97.08	16862/19307	16862/17369
Vegetație acvatică	48.98	21.04	625/1276	625/2971

Tabel A.2.16 - Precizia de estimare si de interpretare pentru rezultatele clasificarii prin metoda probabilității maxime - imaginea Landsat 8

Clasa	Precizia de estimare	Precizia de interpretare	Precizia estimarii	Precizia de interpretare
	(procent)	(procent)	(pixeli)	(pixeli)
Vegetație terestră	68.9	81.76	381/553	381/466
Nori	96.02	59.29	386/402	386/651
Apă limpede	58.1	99.35	10843/18663	10843/10914
Vegetație acvatică	82.95	9.63	827/997	827/8584

Tabel A.2.17 - Precizia de estimare si de interpretare pentru rezultatele clasificarii prin metoda unghiului spectral - imaginea Landsat 8

Clasa	Precizia de estimare	Precizia de interpretare	Precizia estimarii	Precizia de interpretare
	(procent)	(procent)	(pixeli)	(pixeli)
Vegetație terestră	77.82	61.38	677/870	677/1103
Nori	40.55	95.16	118/291	118/124
Apă limpede	89.95	97.25	17108/19019	17108/17591
Vegetație acvatică	44.42	19.61	478/1076	478/2438

Tabel A.2.18 - Precizia de estimare si de interpretare pentru rezultatele clasificarii prin rețelelor neuronale artificiale - imaginea Landsat 8

Clasa	Precizia de estimare	Precizia de interpretare	Precizia estimarii	Precizia de interpretare
	(procent)	(procent)	(pixeli)	(pixeli)
Vegetație terestră	77.1	57.39	734/952	734/1279
Vegetație acvatică	50.27	24.08	640/1273	640/2658
Nori	84.82	60.67	162/191	162/267
Apă limpede	88.03	97.16	16744/19021	16744/17233

Tabel A.2.19 - Erorile de includere si de omisiune pentru rezultatele clasificarii prin metoda distanței minime - imaginea Landsat 7

Clasa	Eroare de includere	Eroare de omisiune	Eroare de atribuire	Eroare de omisiune
	(procent)	(procent)	(pixeli)	(pixeli)
Vegetație acvatică	65.61	41.35	1740/2652	643/1555
Apă limpede	12.65	14.85	2181/17235	2625/17679
Apă cu turbiditate ridicata	39.77	64.55	702/1765	1936/2999
Vegetație terestră	36.03	7.99	642/1782	99/1239

Tabel A.2.20 - Erorile de includere si de omisiune pentru rezultatele clasificarii prin metoda unghiului spectral - imaginea Landsat 7

Clasa	Eroare de includere	Eroare de omisiune	Eroare de atribuire	Eroare de omisiune
	(procent)	(procent)	(pixeli)	(pixeli)
Vegetație terestră	27.93	50.85	236/845	630/1239
Vegetație acvatică	66.45	51.19	1503/2262	796/1555
Apă limpede	6.71	24.14	965/14376	4268/17679
Apă cu turbiditate ridicata	12.4	36.38	270/2178	1091/2999

Tabel A.2.21 - Erorile de includere si de omisiune pentru rezultatele clasificarii prin metoda rețelelor neuronale artificiale - imaginea Landsat 7

Clasa	Eroare de includere	Eroare de omisiune	Eroare de atribuire	Eroare de omisiune
	(procent)	(procent)	(pixeli)	(pixeli)
Vegetație terestră	33.29	11.86	545/1637	147/1239
Vegetație acvatică	76.73	16.78	4268/5562	261/1555
Apă limpede	1.73	33.62	206/11942	5943/17679
Apă cu turbiditate ridicata	35.27	10.47	1463/4148	314/2999

Tabel A.2.22 - Erorile de includere si de omisiune pentru rezultatele clasificarii prin metoda paralelipiped - imaginea Landsat 8

Clasa	Eroare de includere	Eroare de omisiune	Eroare de atribuire	Eroare de omisiune
	(procent)	(procent)	(pixeli)	(pixeli)
Vegetație terestră	15.59	35.65	65/417	195/547
Nori	1.23	1.23	2/162	2/162
Apă limpede	1.56	23.21	219/14002	4167/17950
Vegetație acvatică	86.08	23.96	4297/4992	219/914

Tabel A.2.23 - Erorile de includere si de omisiune pentru rezultatele clasificarii prin metoda distanței minime - imaginea Landsat 8

Clasa	Eroare de includere	Eroare de omisiune	Eroare de atribuire	Eroare de omisiune
	(procent)	(procent)	(pixeli)	(pixeli)
Vegetație terestră	42.67	21.24	585/1371	212/998
Nori	0.97	39.29	2/206	132/336
Apă limpede	2.92	12.66	507/17369	2445/19307
Vegetație acvatică	78.96	51.02	2346/2971	651/1276

Tabel A.2.24 - Erorile de includere si de omisiune pentru rezultatele clasificarii prin metoda probabilității maxime - imaginea Landsat 8

Clasa	Eroare de includere	Eroare de omisiune	Eroare de atribuire	Eroare de omisiune
	(procent)	(procent)	(pixeli)	(pixeli)
Vegetație terestră	18.24	31.1	85/466	172/553
Nori	40.71	3.98	265/651	16/402
Apă limpede	0.65	41.9	71/10914	7820/18663
Vegetație acvatică	90.37	17.05	7757/8584	170/997

Tabel A.2.25 - Erorile de includere si de omisiune pentru rezultatele clasificarii prin metoda unghiului spectral - imaginea Landsat 8

Clasa	Eroare de includere	Eroare de omisiune	Eroare de atribuire	Eroare de omisiune
	(procent)	(procent)	(pixeli)	(pixeli)
Vegetație terestră	38.62	22.18	426/1103	193/870
Nori	4.84	59.45	6/124	173/291
Apă limpede	2.75	10.05	483/17591	1911/19019
Vegetație acvatică	80.39	55.58	1960/2438	598/1076

Tabel A.2.26 - Erorile de includere si de omisiune pentru rezultatele clasificarii prin metoda rețelelor neuronale artificiale - imaginea Landsat 8

Clasa	Eroare de includere	Eroare de omisiune	Eroare de atribuire	Eroare de omisiune
	(procent)	(procent)	(pixeli)	(pixeli)
Vegetație terestră	42.61	22.9	545/1279	218/952
Vegetație acvatică	75.92	49.73	2018/2658	633/1273
Nori	39.33	15.18	105/267	29/191
Apă limpede	2.84	11.97	489/17233	2277/19021