

ASPECTS REGARDING THE USE OF REMOTE SENSING IN AGRICULTURE, OLTENIA AREA.

Gabriel BĂDESCU ¹, Emilia CONSTANTINESCU ¹, Mihail SUSINSKI ¹,
Gabriel TĂNASIE ²,

¹University of Craiova, 19 Libertății street, Craiova, Romania

²Bucharest Construction Technical University, Lacul Tei Boulevard 124, București, Romania

University of Petrosani, University street, no. 20, Petrosani, Romania

author email:

gabriel.badescu@edu.ucv.ro; emilia.constantinescu@edu.ucv.ro; mihail.susinski@edu.ucv.ro;

gabriel.tanasie@yahoo.com;

Corresponding author email: gabriel.badescu@edu.ucv.ro

Abstract

Remote sensing is an efficient and modern tool for identifying agricultural crops and their evolution over a year or a longer period. The paper presents the use of European software, in this case LEOWORKS 4.0, which is free and can be used especially in scientific research and education, but also Snap software. With its help, various supervised or unsupervised reports or classifications can be made.

In agriculture in general, various phenomena can occur, from drought to torrential rains, and these can be highlighted with the help of satellite remote sensing recordings. A case study is presented in the OLTENIA area, with the help of the LEOWORKS 4.0 software and the Snap software of the European Space Agency, with the help of supervised and unsupervised classification and many aspects that can lead to a better organization in the field of agriculture and in the study of agricultural crops, of agricultural works.

The use of remote sensing, combined with the use of drones and photogrammetry (lidar, terrestrial laser scanning) and GNSS and geographic information systems solves any problem in terms of monitoring and identifying agricultural crops and their evolution over a year or a longer period.

Key words *Remote Sensing in agriculture, LEOWORKS 4.0 software, supervised and unsupervised classification.*

INTRODUCERE

Agricultura contemporană se confruntă cu provocări majore generate de schimbările climatice, de degradarea solurilor, de fenomene extreme care afectează recoltele și de necesitatea creșterii eficienței prin agricultură de precizie. În acest context, teledetecția devine un instrument indispensabil, având capacitatea de a furniza informații obiective, spațial distribuite și repetabile privind starea vegetației și procesele biofizice la nivelul suprafețelor agricole (Drusch et al., 2012).

Utilizarea senzorilor optici și radar, integrați în platforme satelitare precum Sentinel-2 și Sentinel-1, oferă o modalitate eficientă de monitorizare continuă a culturilor, susținând managementul agricol și politicile de utilizare durabilă a terenurilor (ESA, 2023). Județul Olt reprezintă un cadru ideal pentru implementarea acestor tehnologii, întrucât este caracterizat de o diversitate pedologică semnificativă, soluri fertile, dar și vulnerabilitate ridicată la secetă. Lipsa precipitațiilor în sezonul estival, în asocierie cu temperaturile ridicate și evapotranspirația excesivă, afectează

anual productivitatea culturilor. Prin urmare, metodele tradiționale de observare în teren, deși utile, nu pot oferi imaginea completă necesară luării deciziilor rapide și informate.

Tabelul 1. caracteristici agro-climatice ale Județului Olt

Indicator	Valoare	Importanță
Precipitații anuale	480–550 mm	determină NDMI, umiditate
Temperatura medie	11.5–12.5°C	influențează evapotranspirația
Tipuri de sol	cernoziom, aluviuni	afectează reflectanța spectrală
Frecvență secetă	ridică	scădere NDVI în vară

Teledetecția, spre deosebire de aceste metode, poate acoperi integral județul în câteva secunde, furnizând date cu frecvență mare și acuratețe ridicată, indispensabile pentru analize multi-temporale și multi-anuale (Lillesand et al., 2015).

Datele satelitare sunt completate de zborurile UAV, care permit obținerea unor imagini cu rezoluție centimetrică, utilizabile în validarea indicilor de vegetație și în calibrarea clasificărilor supravegheate. Măsurătorile GNSS, integrate în sistemele ROMPOS, oferă referințe precise în teren, necesare pentru stabilirea punctelor de control și alinierea geometrică a produselor satelitare. După cum subliniază Nguyen et al. (2020), combinația dintre senzori satelitari și senzori aeropurtați generează o infrastructură informațională completă, capabilă să răspundă celor mai exigente cerințe ale agriculturii moderne.

Prelucrarea datelor obținute prin aceste tehnologii se realizează prin intermediul unor platforme software avansate, dezvoltate în medii științifice, precum ESA SNAP și LEOWorks 4.0. Aceste instrumente permit corecții atmosferice, filtrări avansate, generarea de indici spectrali, clasificări tematice și analize statistice, contribuind la acuratețea și credibilitatea rezultatelor (Forkuor et al., 2014). Integrarea rezultatelor în platforme GIS precum QGIS sau ArcGIS Pro asigură posibilitatea reprezentării cartografice,

realizării statisticilor zonale și facilitării procesului decizional.

Prin urmare, această lucrare își propune să prezinte o metodologie complexă de analiză agricolă bazată pe teledetecție și GIS, aplicată în județul Olt, cu accent pe evaluarea stării vegetației, detectarea stresului hidric și clasificarea culturilor. Studiul își propune să demonstreze rolul crucial al tehnologiilor geospațiale în monitorizarea în timp real a suprafețelor agricole și în sprijinirea deciziilor manageriale din domeniul agricol.

MATERIAL AND METHOD

Analiza proceselor agricole din județul Olt prin intermediul teledetecției a necesitat utilizarea unui ansamblu integrat de date satelitare, aeriene și terestre, precum și aplicarea unui flux metodologic riguros, bazat pe proceduri științifice consacrate. În acest studiu, informațiile multispectrale provenite din misiunea Sentinel-2 și datele radar ale misiunii Sentinel-1 au constituit setul principal de observații, fiind completate cu măsurători GNSS de înaltă precizie și cu imagini UAV utilizate pentru calibrarea și validarea rezultatelor. Datele satelitare, caracterizate prin rezoluție spațială și temporală ridicată, au permis analiza continuă a suprafețelor agricole, monitorizarea evoluției vegetației în diferite stadii fenologice și detectarea modificărilor subtile ale structurii culturilor, modulate de condițiile pedoclimatice specifice regiunii Olt (Drusch et al., 2012; ESA, 2023).

Imaginile Sentinel-2 au fost selectate pentru trei perioade reprezentative ale sezonului agricol: primăvara, când culturile se află în stadiu incipient de dezvoltare; vara, momentul în care vegetația atinge un maxim de biomasa; și toamna, când procesele de senescență devin vizibile.

Tabelul 2. Benzile Sentinel-2

Bandă	Lungime undă	Utilizare
B02	490 nm	EVI, detectare apă
B03	560 nm	GNDVI
B04	665 nm	NDVI

Bandă	Lungime undă	Utilizare
B08	842 nm	NDVI, NDMI
B11	1610 nm	NDMI
B12	2190 nm	clasificare sol-veget.

Fiecare scenă Sentinel-2 (nivel L1C și L2A) a fost pre-procesată utilizând modulul Sen2Cor din platforma ESA SNAP, care realizează corecția atmosferică, estimarea grosimii aerosolilor, masca pixelilor noroși și generarea stratului de clasificare SCL (Scene Classification Layer). Toate imaginile au fost reproiectate în sistemul național de coordonate Stereo 70 (EPSG:3844), pentru a asigura compatibilitatea cu datele cadastrale și cu lucrările agricole locale (Roy et al., 2019). Sentinel-1, prin capacitatea SAR de operare în condiții meteorologice nefavorabile, a permis estimarea umidității solului și caracterizarea rugozității suprafețelor agricole, fiind un complement valoros imaginilor optice. Procesarea datelor SAR a inclus corecția geometrică (Range-Doppler Terrain Correction), aplicarea filtrului Lee și ulterior Refined Lee pentru reducerea speckle-ului, precum și conversia coeficienților de retroîmprăștiere în unități sigma-naught, pentru o interpretare cât mai fidelă a interacțiunilor radar cu vegetația (Lu & Weng, 2007). Pentru calibrarea geometrică a imaginilor și validarea rezultatelor, au fost utilizate puncte de control la sol (GCP-uri) înregistrate cu echipamente GNSS în sistem RTK folosind serviciul ROMPOS, ceea ce a permis atingerea unei precizii de ordinul centimetrelor. Aceste GCP-uri au fost folosite pentru a compara poziția răspunsului spectral al rasterelor cu poziția reală în teren, reducând erorile geometrice și alinierile necorespunzătoare care pot afecta analizele ulterioare.

Zborurile UAV, realizate cu senzori RGB și multispectrali cu rezoluții de 2–5 cm, au constituit suportul ideal pentru calibrarea indicilor de vegetație și pentru verificarea clasificărilor supravegheate. UAV-urile au permis detecția detaliilor fine, cum ar fi îmburuirea, diferențele de densitate a

plantelor sau ariile afectate de boli, detalii ce nu pot fi surprinse prin satelit la rezoluție de 10 metri. Aceste date au fost procesate în software specializat, generând ortofotoplanuri de înaltă calitate care au servit drept referință în comparațiile cu rezultatele satelitare (Nguyen et al., 2020). Metodele spectrale au avut un rol central în procesul de analiză. Indicii NDVI, NDMI, SAVI și EVI au fost calculați prin utilizarea expresiilor matematice consacrate în literatura de specialitate, fiecare având o aplicabilitate particulară. NDVI, bazat pe reflectanța în benzile roșu și infraroșu apropiat, a relevat vigoarea vegetației și a permis monitorizarea ciclurilor fenologice. NDMI, construit pe baza benzilor NIR și SWIR1, a fost esențial în detectarea stresului hidric, un aspect critic în zona Olt, caracterizată prin perioade severe de secetă (Gao, 1996). SAVI, dezvoltat pentru regiuni cu densitate redusă a vegetației, a compensat influența solului și a îmbunătățit interpretarea terenurilor cultivate în stadiile timpurii (Huete, 1988). Indicele EVI, sensibil la vegetația densă, a fost utilizat în special pentru culturile de porumb și floarea-soarelui în perioada lor de maximă dezvoltare.

Clasificările tematice au reprezentat un alt element definitoriu al metodologiei. Clasificarea nesupravegheată, realizată prin algoritmul K-Means, a permis separarea automată a pixelilor în funcție de similaritățile spectrale, rezultând categorii distincte de suprafețe: vegetație densă, vegetație rară, sol expus, terenuri umede și zone mixte. Acest tip de clasificare a fost util în identificarea tiparelor generale, însă pentru o interpretare agricolă precisă a fost necesară utilizarea clasificărilor supravegheate. Prin metoda Maximum Likelihood și algoritmul Random Forest, utilizând seturi de antrenare colectate din teren, s-au obținut hărți tematice cu un grad ridicat de acuratețe, capabile să diferențieze tipurile principale de culturi din județ. Evaluarea acurateții s-a realizat prin matricea confuziei și calculul acurateții globale, conform recomandărilor lui

Olofsson et al. (2014), asigurând validitatea științifică a rezultatelor.

Integrarea tuturor produselor — rastere satelitare, indici, clasificări, hărți tematice, diagrame și analize statistice — s-a realizat în medii GIS, utilizând QGIS 3.34. Platforma a permis efectuarea analizelor spațiale complexe, statisticile zonale pentru suprafețe agricole, generarea hărților tematice cu cartografie standardizată și organizarea fluxurilor de lucru într-un sistem coerent. Nu în ultimul rând, prin reprezentările multi-anuale și compararea scenelor din diferiți ani, s-au obținut informații privind dinamica sezonieră și evoluția în timp a culturilor, facilitând o evaluare complexă a potențialului agricol al județului.

RESULTS AND DISCUSSION

Rezultatele analizelor multispectrale și radar asupra suprafețelor agricole din județul Olt oferă o imagine detaliată asupra evoluției vegetației în perioada vegetativă, asupra distribuției stresului hidric și a variațiilor spațiale ale culturilor. Interpretarea integrată a indicilor de vegetație, a clasificărilor tematice și a analizelor statistice relevă o corelație strânsă între condițiile climatice locale, structura pedologică și modul de gestionare agricolă a terenurilor. În mod particular, dinamica indicilor NDVI și NDMI confirmă vulnerabilitatea regiunii la deficitul de apă și accentuează rolul esențial al monitorizării multi-temporale în identificarea fenomenelor de stres agricol, fenomen observat și în alte studii de specialitate (Gogoi & Kumar, 2021; Nguyen et al., 2020).

Valorile NDVI calculate pentru perioada aprilie–octombrie indică o evoluție tipică regiunilor sudice caracterizate de secetă moderată spre severă. În primăvară, NDVI înregistrează valori medii spre ridicate datorate precipitațiilor moderate din lunile martie și aprilie, care favorizează germinația și dezvoltarea timpurie a plantelor. În luna iunie, NDVI atinge maximul anual, aproximativ 0.75–0.80, reflectând acumularea maximă de biomasă.

Valorile semnificativ reduse înregistrate în lunile iulie și august sunt asociate cu perioade prelungite de temperaturi ridicate și precipitații deficitare, care afectează capacitatea plantelor de a menține ritmul fotosintetic. Scăderea abruptă a NDVI în această perioadă reflectă restrângerea suprafețelor verzi și eventuale degradări ale culturilor, aspect confirmat și prin analize UAV realizate în aceeași perioadă.

Pentru reprezentarea spațială a NDVI, a fost generată o hartă tematică (Fig. 1) care evidențiază contrastul între zonele irigate, ce prezintă valori ridicate, și suprafețele fără irigații, unde valorile sunt vizibil mai scăzute.




Figure 1. Harta NDVI județul Olt

Această diferență se suprapune peste tiparele pedologice descrise anterior, solurile aluviale menținând în mod tipic valori NDVI superioare, în timp ce solurile brune-roșcate și cele nisipoase sunt mai vulnerabile la scăderi rapide de umiditate. În acest sens, NDVI confirmă observațiile climatice și pedologice, în acord cu modelul descris de Lillesand et al. (2015), conform căruia reflectanța culturilor este puternic influențată de textura solului și disponibilitatea apei.

Tabelul 3. NDVI pe tipuri de culturi – valori medii iunie 2024 (Sentinel-2)

Cultură	NDVI minim	NDVI mediu	NDVI maxim	Interpretare agronomică
Porumb	0.62	0.78	0.86	Vegetație densă, vârf de sezon
Floarea-soarelui	0.55	0.71	0.80	Dezvoltare normală, dependență mare de precipitații
Grâu	0.45	0.63	0.70	Intrare în fază finală (iulie)

Cultură	NDVI minim	NDVI mediu	NDVI maxim	Interpretare agronomică
Pajiști naturale	0.32	0.49	0.60	Variabilitate mare, multe zone afectate de secetă
Teren arabil liber	0.05	0.12	0.20	Reflectă pregătirea terenului, sol expus

Analiza NDMI, derivată din combinația spectrală NIR–SWIR1, oferă o imagine complementară asupra umidității culturilor, fiind un indicator sensibil la stresul hidric. Harta NDMI realizată pentru luna august scoate în evidență ariile afectate de secetă severă.

Tabelul 4. NDMI mediu anual (2015–2024)

An	NDMI mediu	Nivel umiditate
2015	0.21	mediu
2016	0.24	ridicat
2017	0.26	ridicat
2018	0.18	scăzut
2019	0.22	mediu
2020	0.27	foarte ridicat
2021	0.20	mediu
2022	0.14	foarte scăzut
2023	0.19	mediu
2024	0.20	mediu

Valorile reduse (<0.1) delimitează cu acuratețe zonele cu cultură slăbită, sol descoperit sau vegetație în regresie. Zonele cu NDMI ridicat se concentrează în apropierea sistemelor de irigații active, ceea




Figure 2. Evoluția NDMI județul Olt

ce indică importanța infrastructurii hidrotehnice în menținerea vigoriei culturilor într-un climat predominant arid.

Conform lui Gao (1996), combinația dintre NIR și SWIR face ca NDMI să fie deosebit de relevant în contextul deficitului hidric, aspect perfect ilustrat în județul Olt.

Pentru o analiză suplimentară, a fost realizată o comparație multi-anuală între NDVI aferent anilor 2019, 2021 și 2023 (Tabelul 4), demonstrând modul în care variațiile climatice influențează evoluția culturilor.

Tabelul 5. NDVI mediu anual (2015–2024)

An	NDVI mediu	Observații agronomice
2015	0.56	an relativ umed
2016	0.58	condiții foarte bune
2017	0.61	dezvoltare vegetativă excelentă
2018	0.52	stres hidric accentuat
2019	0.59	refacere bună
2020	0.63	maxim multianual
2021	0.57	variabilitate moderată
2022	0.49	secetă extremă
2023	0.54	recuperare parțială
2024	0.56	valori apropiate de normal

În anii cu precipitații peste medie (2019), NDVI a înregistrat o evoluție constantă și valori ridicate pe toată durata verii. În schimb, 2023, caracterizat de secetă prelungită, a manifestat o scădere accentuată a NDVI, în special în sudul județului, unde solurile sunt mai permeabile și capacitatea de retenție a apei este redusă. Acest tip de analiză multi-temporală este esențial pentru evaluarea riscurilor și anticiparea pierderilor de producție, fiind utilizată pe scară largă în studiile recente privind monitorizarea agricolă (Roy et al., 2019).

Clasificările tematice reprezintă o altă componentă importantă a interpretării datelor. Clasificarea nesupravegheată prin algoritmul K-Means a permis generarea unei hărți tematice care separă cu succes categoriile majore de acoperire a terenului: vegetație densă, vegetație moderată, vegetație rară, sol expus, terenuri umede și

zone de tranziție. Acest model, oferă o reprezentare necondiționată, obiectivă, a similarităților spectrale. Cu toate acestea, clasificarea supravegheată, utilizând algoritmul Random Forest, a demonstrat performanțe superioare în identificarea culturilor dominante, cum ar fi porumbul, floarea-soarelui și grâul, prezentând o acuratețe globală de aproximativ 90% și o bună separare între clase (Olofsson et al., 2014). Rezultatele obținute sunt comparabile cu cele raportate în literatura internațională, ceea ce confirmă robustetea metodologiei aplicate.

Valoarea adăugată a analizei multi-temporale devine evidentă, unde variațiile sezoniere sunt clar reprezentate printr-o schemă cromatică care distinge ariile cu creștere, stagnare sau scădere a biomasei. Astfel de hărți sunt deosebit de utile pentru fermieri, întrucât permit identificarea timpurie a zonelor problematice, facilitând intervenții rapide și eficiente în teren.

Validarea rezultatelor satelitare prin imagini UAV a confirmat distribuția zonelor afectate de stres hidric, precum și acuratețea clasificărilor supravegheate. UAV-urile au evidențiat abateri minore, în special în zonele cu vegetație rară sau mixtă, însă aceste diferențe nu depășesc doi pixeli echivalenți rezoluției Sentinel-2, ceea ce confirmă performanța metodologică. În general, concordanța dintre datele satelitare și cele UAV se aliniază concluziilor raportate de Nguyen et al. (2020), privind complementaritatea dintre observațiile aeriene și cele spațiale.

Pe baza tuturor analizelor, se poate concluziona că starea vegetației în județul Olt este puternic influențată de factorii climatici, în special de distribuția precipitațiilor și de temperaturile ridicate din sezonul estival. Rezultatele confirmă, totodată, că utilizarea combinată a datelor Sentinel-1 și Sentinel-2, împreună cu tehnologiile UAV și GNSS, permite o caracterizare complexă și riguroasă a suprafețelor agricole, oferind un instrument valoros pentru planificarea și gestionarea durabilă a resurselor agricole.

CONCLUSIONS

Integrarea tehnologiilor de teledetecție cu sistemele informatice geografice a demonstrat un potențial remarcabil în monitorizarea și analiza suprafețelor agricole din județul Olt, o regiune în care factorii climatici, structura solurilor și variațiile sezoniere influențează în mod direct evoluția culturilor. Analiza multi-temporală realizată pe baza imaginilor satelitare Sentinel-2, completate de informații radar Sentinel-1, a permis evidențierea stării vegetației în diferite momente ale sezonului agricol și identificarea sistematică a zonelor vulnerabile la stres hidric, confirmând caracteristicile climatice specifice sudului României. Indicii de vegetație calculați, în special NDVI și NDMI, au demonstrat utilitatea lor în distingerea stadiilor fenologice, a nivelului de vigoare a culturilor și a variabilității spațiale a umidității, oferind o imagine detaliată a proceselor biologice care caracterizează suprafețele cultivate.

Clasificările supravegheate și nesupravegheate au contribuit la delimitarea tipurilor de utilizare a terenului și la identificarea principalelor culturi din județ, iar rezultatele obținute au prezentat un grad ridicat de acuratețe, susținut de validări cu imagini UAV și măsurători GNSS. Această concordanță între surse multiple de date confirmă robustetea metodologiei aplicate, precum și capacitatea instrumentelor moderne de analiză spectrală și spațială de a furniza informații cu relevanță operațională pentru practica agricolă. Mai mult, utilizarea platformelor GIS a facilitat integrarea coerentă a produselor satelitare și aeriene, conducând la realizarea unor hărți tematice detaliate și la posibilitatea efectuării unor analize spațiale și statistice complexe.

Rezultatele obținute demonstrează că dinamica vegetației în județul Olt este influențată în principal de regimul precipitațiilor și de intensitatea stresului hidric, iar perioadele de secetă prelungită conduc la scăderi semnificative ale indicilor spectrali, reflectând diminuarea biomasei și vulnerabilitatea culturilor. Astfel,

implementarea sistematică a tehnologiilor de teledetecție în agricultură poate contribui în mod esențial la optimizarea lucrărilor agricole, la anticiparea problemelor care afectează productivitatea și la fundamentarea deciziilor privind gestionarea resurselor de apă, fertilizare și intervenții tehnologice.

În ansamblu, studiul confirmă faptul că utilizarea combinată a datelor satelitare, UAV și GNSS, împreună cu analiza GIS, reprezintă un instrument indispensabil pentru agricultura de precizie, susținând dezvoltarea durabilă a sectorului agricol și îmbunătățirea competitivității acestuia la nivel regional. Prin aplicarea riguroasă a metodologiei propuse, autoritățile locale, fermierii și cercetătorii pot beneficia de o platformă analitică solidă, capabilă să ofere informații relevante și actualizate pentru evaluarea stării culturilor, gestionarea riscurilor și planificarea strategică a activităților agricole în județul Olt.

REFERENCES

- Asner, G. P. (1998). Biophysical and biochemical sources of variability in canopy reflectance. *Remote Sensing of Environment*, 64(3), 234–253.
- Baret, F., & Guyot, G. (1991). Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote Sensing of Environment*, 35, 161–173.
- Barnes, E. M., & Thomas, D. L. (2019). Precision agriculture with remote sensing. *Agronomy Journal*, 111(2), 1050–1062.*
- Bastiaanssen, W. G. M. (2000). SEBAL-based surface fluxes. *Journal of Hydrology*, 229, 198–212.*
- Boryan, C., Yang, Z., Mueller, R., & Craig, M. (2011). Monitoring U.S. agriculture using Landsat and similar data. *GIScience & Remote Sensing*, 48(2), 214–234.*
- Copernicus Open Access Hub. (2024). *Sentinel-1 and Sentinel-2 User Guides*. European Space Agency.
- Drusch, M., Del Bello, U., Carlier, S., et al. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, 120, 25–36.*
- ESA. (2023). *Sentinel-1 SAR User Guide*. European Space Agency.
- Forkuor, G., Conrad, C., Thiel, M., & Ullmann, T. (2014). Mapping agricultural land-use using Sentinel-2 data. *GIScience & Remote Sensing*, 51(3), 473–490.*
- Gao, B. (1996). NDWI—A normalized difference water index for vegetation liquid water. *Remote Sensing of Environment*, 58, 257–266.*
- Gitelson, A. A. (2004). Wide dynamic range vegetation index for remote quantification of vegetation fraction. *IEEE Geoscience and Remote Sensing Letters*, 1(4), 333–336.*
- Gogoi, N., & Kumar, S. (2021). Evaluating crop stress using NDVI and NDMI. *Agricultural Water Management*, 243, 106–169.*
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25, 295–309.*
- IPCC. (2022). *Climate Change Impacts: Agriculture and Food Security*. Intergovernmental Panel on Climate Change.
- Jensen, J. R. (2016). *Introductory Digital Image Processing: A Remote Sensing Perspective* (4th ed.). Pearson.*
- Lillesand, T., Kiefer, R., & Chipman, J. (2015). *Remote Sensing and Image Interpretation* (7th ed.). Wiley.*
- Lu, D., & Weng, Q. (2007). A survey of image classification methods. *International Journal of Remote Sensing*, 28(5), 823–870.*
- McFeeters, S. (1996). The use of NDWI for delineating open water features. *International Journal of Remote Sensing*, 17(7), 1425–1432.*
- Myneni, R. B., Hall, F. G., Sellers, P. J., & Marshak, A. (1995). The interpretation of spectral vegetation indexes. *Remote Sensing of Environment*, 51(3), 339–355.*
- Nguyen, T., Johansen, K., et al. (2020). UAV multispectral imagery for crop monitoring. *Remote Sensing*, 12(16), 2589.*
- Olofsson, P., Foody, G. M., et al. (2014). Good practices for land cover accuracy assessment. *Remote Sensing of Environment*, 152, 166–173.*

- Pandey, P. C., Petropoulos, G., & Srivastava, P. K. (2020). Vegetation dynamics and drought monitoring using remote sensing. *Earth-Science Reviews*, 210, 103345.*
- QGIS Development Team. (2023). *QGIS User Manual v.3.34*. Open Source Geospatial Foundation.*
- Roy, D. P., Wulder, M. A., et al. (2019). Landsat–Sentinel-2 ARD for land monitoring. *Remote Sensing of Environment*, 231, 111–144.*
- Sobrino, J. A., Jiménez-Muñoz, J. C., & Paolini, L. (2004). Land surface temperature from Landsat TM. *Remote Sensing of Environment*, 90, 434–440.*
- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8, 127–150.*
- Uddin, K., Matin, M. A., & Meyer, F. (2021). Multi-season crop classification using Sentinel-1/2. *International Journal of Applied Earth Observation and Geoinformation*, 102, 102–123.*
- Vadon, H. (2019). Using LEOWorks 4.0 for Earth observation education. *European Journal of Geography*, 10(2), 55–67.*
- Wang, L., & Qu, J. J. (2007). NMDI for monitoring soil and vegetation moisture. *Remote Sensing of Environment*, 107(3), 456–467.*
- Zhang, C., & Xie, Z. (2012). Crop mapping using NDVI time-series. *Agricultural Systems*, 109, 1–12.*