

PALYDOVINIŲ VAIZDŲ SINTEZĖS IR SEGMENTAVIMO TAIKYMAS TIRIANT ŽEMĖS DANGĄ

Gustė Metrikaitytė¹, Jūratė Sužiedelytė Visockienė²

¹magistrė, ²profesorė,

Vilniaus Gedimino technikos universitetas,

El. p.: ¹gusmeta@gmail.com; ²juratesuziedelyte-visockiene@vilniustech.lt

Anotacija. Šio darbo tikslas – naudojant palydovinių vaizdų sintezę ir segmentavimą, įvertinti nustatytų žemės dangos pokyčių 2018–2019 m. laikotarpiu identifikavimo kokybę. Straipsnyje apžvelgiami palydovinių vaizdų segmentavimo metodai ir jų taikymas žemės dangos tyrimuose, naudojant palydovinių vaizdų sintezę. Tyrimui buvo pasirinkti viešai pasiekiami ir nemokami Europos kosmoso agentūros platinami „Sentinel-1“ sintetinės apertūros radaro ir „Sentinel-2“ multispektriniai palydoviniai vaizdai. Tyrimo metu buvo atlikta šių vaizdų sintezė, segmentavimas ir nustatyti žemės dangos pokyčiai. Straipsnyje pateikti identifikuotų žemės dangos pokyčių ir kokybinio tikslumo tyrimo rezultatai bei išvagos.

Reikšminiai žodžiai: SAR, MSI, sintezė, segmentavimas, palydoviniai vaizdai, žemės danga.

Įvadas

Palydovinių vaizdų segmentavimas yra vienas svarbiausių radaro ir optinio jutiklio duomenų apdorojimo procesų. Segmentavimo metodų yra ne vienas, tačiau du populiariausi ir plačiausiai taikomi yra nekontroliuojamas (angl. *Unsupervised*) ir kontroliuojamas (angl. *Supervised*) segmentavimo metodai. Kontroliuojamas žemės dangos segmentavimas vyksta pagal parinktus žemėnaudų klasių pavyzdžius (pavyzdžių (angl. *Samples*) biblioteką), procesas kontroliuojamas operatoriaus, todėl šio metodo tikslumas yra didesnis (Wang et al., 2018). Nekontroliuojamo segmentavimo rezultatas (pikselių grupavimas su bendromis savybėmis) grindžiamas programine vaizdo analize be operatoriaus pateiktų pavyzdinių klasių tik parinkus jų skaičių. Naudojant algoritmą nuotraukoje tarpusavyje susiję pikseliai sugrupuojami į nustatyto skaičiaus klasterius. Operatorius turi žinoti apie segmentuojamą sritį, kad vėliau ją galėtų priskirti faktinėms žemės savybėms (pvz., pelkės, urbanizuotos teritorijos, miškai ir kt.). Taikant tiek kontroliuojamo, tiek nekontroliuojamo segmentavimo metodus, operatoriaus indėlis būtinas: kontroliuojamo metodo – proceso pradžioje, nekontroliuojamo – gale. Rengiant šį straipsnį buvo taikytas kontroliuojamas (angl. *Supervised*) segmentavimo metodas.

Vaizdų segmentavimo metodai, priklausomai nuo proceso, skirstomi į kategorijas (Blaschke et al., 2014):

- pikselių pagrindu (angl. *Pixel-based or Point-based*);
- kontūrų pagrindu (angl. *Edge-based*);
- regionų pagrindu (angl. *Region-based*);
- kombinuotu būdu.

Pikseliais pagrįsti metodai dominavo nuotolinio stebėjimo vaizdų analizėje nuo pat vaizdų segmentavimo pradžios, tačiau pastebėta, kad išskirti regionai teikia daug daugiau informacijos nei pavieniai pikseliai (Barbedo et al., 2018). Terminas *piksėlis* nuotolinių tyrimų srityje turi kitą kontekstą nei kompiuteryje regėjimas ir vaizdo apdorojimas. Nuotoliniuose tyrimuose pikselis gali atstovauti didelei teritorijai, turinčiai įvairių savybių. Pikselis gali apimti daug įvairių objektų, tokių kaip pastatai, kelių segmentai ir skirtingi dirvožemio tipai bei dangos. Naujausių palydovų jutiklių skiriamoji geba gali būti ir apie 1 m, tačiau kiekvienas taškas vis tiek gali apimti kelis objektus ar paviršius. Individualių objektų atpažinimui tai gali sukelti problemų. Segmentuojant žemės naudmenas siekiama išskirti regioną, todėl vietoj atskirų objektų svarbios jų kumuliacinės (spektrinės) charakteristikos. Kiekviename pikselyje apibendrinamas didelis regionas, suskaičiuojama bendra (vidutinė) spektrinė signatūros (spalvos intensyvumo) vertė.

Kontūrų pagrįstu metodu pirmiausia ištiriamas objekto ribos, o vėliau, nustačius objektą, jos užsipildo. Regiono pagrindu atvirkščiai, analizuojamas pikselių (ieškoma vienetų reikšmių) vidus ir vėliau apibrėžiamas

kontūras. Abiem atvejais gauti rezultatai gali būti skirtingi. Vaizdų segmentavimas regionų pagrindu taikomas atsiradus didelės skiriamosios gebos palydoviniams vaizdams, tarp jų ir „Sentinel“. Tyrimai rodo, kad šis metodas daug geriau išskiria klasės spektrinį kintamumą, nei taikant tradicinius pikseliais pagrįstus metodus (Blaschke et al., 2014). Vienas svarbus veiksnys, į kurį reikia atsižvelgti taikant regionų metodą, yra parinktas teisingas segmento dydis. Nustatytas per didelis parametras gali turėti įtakos dideliui skaičiui nevienalyčių objektų, o per mažas gali sukurti labai daug mažų objektų, iš kurių bus sunku išgauti reikiamas klases. Pastaraisiais metais vaizdų segmentavimas glaudžiai siejamas ir su mašininio mokymo sritimi.

Palydovinių vaizdų segmentavimas

Segmentuojant palydovinius vaizdus, atliekami penki veiksmi (Park & Lu, 2015):

- vaizdo atsisiuntimas;
- vaizdo pirminis apdorojimas (angl. *pre-processing*), siekiant gauti patobulintą vaizdą, t. y. jį pataisyti dėl atmosferos įtakos, reljefo pokyčių;
- pavyzdžių rinkimas segmentavimo algoritmui apmokyti;
- vaizdo požymių išskyrimas, t. y. objektų charakteristikų, dydžio, formos, spalvos ir tekstūros išskyrimas iš segmentuojamo vaizdo;
- vaizdo segmentavimas pagal surinktus pavyzdžius, taip gaunant vaizdą suskirstytomis objektų grupėmis (pvz., miškai, vandenys, smėlynai ir t. t.).

Palydoviniai duomenys gali būti radariniai arba optiniai, jie skiriasi tiek savo fizikinėmis savybėmis, tiek pačių vaizdų gavimo principu.


Šiame straipsnyje apžvelgsime optinių (toliau – MSI) ir sintetinės apertūros radaro (toliau – SAR) duomenų paruošimo ir apdorojimo metodiką, kurioje žemės dangos pokytis identifikuojamas sujungiant skirtingų laikotarpių ir SAR vaizdus į vieną bendrą vaizdą ir jį segmentuojant, taip išskiriant 6 žemės dangos klases, kurias kitame etape sukertamos, siekiant gauti žemės dangos pokytį analizuojamu laikotarpiu.

SAR duomenų paruošimas ir pirminis apdorojimas

Pasirinkti Europos kosmoso agentūros (angl. *Europe Space Agency*, ESA) platinami ir visiems nemokamai pasiekiami „Sentinel-1“ SAR ir „Sentinel-2“ DSI palydoviniai vaizdai, kuriuos galima atsisiųsti iš „Copernicus Open Access Hub“ tinklalapio (Open Access Hub, 2021). Objektas – 2000 km² teritorija, esanti vakarų Lietuvoje (Klaipėdos apskritis). Ši teritorija pasirinkta

dėl žemės dangos įvairovės, į kurią patenka viena iš Lietuvos aglomeracijų (Klaipėdos), mažiau urbanizuotos teritorijos (Palanga, Kretinga, Kretingalė, Gargždai ir pan.), pagrindiniai ir šalutiniai keliai, miškingos teritorijos, dirbami laukai, pievos, smėlingos teritorijos, kopos pajūryje, atviri vandenys (Baltijos jūra), lagūna (Kuršių marios), uždari vandenys (ežerai, tvenkiniai), upės, pelkės ir t. t. Tyrime naudoti 2018 ir 2019 metų birželio–rugpjūčio mėnesių 13 „Sentinel-1“ S1A palydovo vaizdų ir 9 „Sentinel-2“ S2A arba S2B palydovo vaizdai, kurių debesuotumas neviršijo 15 %.

SAR vaizdų pirminis duomenų apdorojimas atliktas naudojant „Graph Builder“ funkciją ESA SNAP atvirojo kodo programoje (SNAP ESA Documentation, 2020). Pirmu pirminio apdorojimo žingsniu atliktas palydovo padėties ir greičio informacijos tikslinimas (angl. *Apply-Orbit-File*). Šis veiksmas yra labai svarbus lokalizuojant vaizdą. Labai tiksli vaizdo padėtis yra svarbu skirtingų duomenų sintezės procese. Realiuoju laiku, kai daromos SAR nuotraukos, informacija apie tikslią palydovo padėtį nėra žinoma, todėl produkto metaduomenyse būna užfiksuojama tik abstrakti informacija. Naudojant orbitos failo taikymo įrankį ESA SNAP programoje, patikslinama palydovo padėties ir greičio informacija. Tam naudojami orbitos failai, kurie pasiekiami kelios dienos ar savaitės po vaizdo užfiksavimo. ESA SNAP programoje šie failai atsiumčiami automatiškai (SNAP ESA Documentation, 2020). Toliau kalibruojami duomenys. Šio proceso metu palydovinis vaizdas įgauna tikrąsias atsispindėjusių spindulių reikšmes (sigma, beta, gama), originalioje nuotraukoje esančios juostos ir rėžiai sujungiami į vieną bendrą vaizdą ir vaizdas perskaičiuojamas (angl. *Multilook*), kad būtų sudarytas iš vienodo dydžio gardelių (pikselių). Papildomai buvo taikomas dėmių filtras (angl. *Speckle-Filter*), kuris sumažino vaizduose atsiktinai įsiterpusias dėmes (angl. *Speckle*), apsunkinančias vaizdų interpretavimą. Šiame tyrime buvo pasirinktas „Lee Sigma“ filtras, kuris naudoja standartinį nuokrypį dėmėms sumažinti vaizde. Identifikuojant skirtingus žemės dangos objektus, yra svarbus pikselių kontrastas, todėl, norint jį išryškinti, reikia vaizdų poliarizacijos juostas transformuoti į logaritminę skalę. Ši funkcija ryškias vertes paslenka link vidurio, o tamsiosios vertės ištempiamos platesniame spalvų diapazone, taip gaunamas didesnis kontrastas tarp kai kurių skirtingų žemės dangos objektų. Originalūs SAR vaizdai dažnu atveju yra iškreipti, o jų padėtis atrodo veidrodinė dėl palydovo orbitos, todėl, atlikus SAR vaizdų pradinį apdorojimą, paskutiniu žingsniu vykdomas geografinis orientavimas, kad vaizdai būtų geografiškai teisingai orientuoti. Šiam veiksmui buvo naudojamas SRTM 1 sec HGT reljefo modelis, 10 m pikselio dydis ir koordinacijų sistema – WGS84 / UTM 34N zona. Apdoroto ir analizei paruošto vaizdo pavyzdys pateiktas 1 paveiksle.



1 paveikslas. Apdorotas ir analizei paruoštas SAR vaizdas – VV, VH, VV/VH poliarizacija

MSI vaizdai yra jau iš dalies apdoroti, t. y. duomenys pataisyti dėl atmosferos, reljefo klaidų, todėl atsisiųsti duomenys yra iškart tinkami duomenų sintezei atlikti ir nereikia jų papildomai apdoroti programine įranga. Tačiau, norint išvengti duomenų pertekliaus ir pagreitinti tolesnius procesus, atliktas vaizdų apkirpimas, t. y. pasirenkamas duomenų pogrupis. Duomenų sintezei nėra reikalingi saulės padėties, azimuto ar kokybės indikatorių duomenys, todėl pasirinktos tik MSI vaizdo juostos, anuluojant juostas, jautrias aerzoliams ir debesims (B1, B9 ir B10 juostos). Naudotas ESA SNAP programinės įrangos pogrupio įrankis *Subset*. Galutinis duomenų produktas sudarytas iš 10-ies elektromagnetinių juostų: B2, B3, B4, B5, B6, B7, B8, B8a, B11, B12. Analizei paruošto vaizdo pavyzdys pateiktas 2 paveiksle.



2 paveikslas. Apdorotas ir analizei paruoštas MSI RGB vaizdas

Duomenų sintezė ir segmentavimas

Atlikus SAR ir MSI vaizdų priminį apdorojimą, papildomai šiems vaizdams apskaičiuojami indeksai, kurie išryškina tam tikras žemės dangos klases. Į vaizdų sujungimą buvo papildomai įtrauktas:

- normalizuotas augmenijos skirtumo indeksas (angl. *Normalized Difference Vegetation Index*) NDVI;
- „Sentinel-2“ raudonojo krašto padėties (angl. *Sentinel-2 Red Edge Position*) S2REP indeksas, kuris yra jautrus pasėlių (chlorofilo kiekiui) ir augimo būklei apibūdinti;
- žalio normalizuoto skirtumo augalijos (angl. *Green Normalized Difference Vegetation Index*) GNDVI indeksas.

Visi indeksai skirti augalijai išryškinti MSI palydoviniuose vaizduose. Taip pat urbanizuotoms teritorijoms išryškinti įtrauktas užstatymo (angl. *Normalized Difference Built-up Index*) NDBI indeksas ir Sigmos santykio (angl. *Sigma_ratio_db index*) indeksas, kuris sumažina SAR vaizdo juostų disbalansą. Indeksų skaičiavimo formulės yra šios:

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)} = \frac{(B8 - B4)}{(B8 + B4)}; \quad (1)$$

$$S2REP = 705 + 35 * \left[\frac{\left(\frac{B7 + B4}{2} \right) - B5}{B6 - B5} \right]; \quad (2)$$

$$GNDVI = \frac{(GREEN - RED)}{(GREEN + RED)} = \frac{(B3 - B4)}{(B3 + B4)}; \quad (3)$$

$$NDBI = \frac{(SWIR - NIR)}{(SWIR + NIR)} = \frac{(B11 - B8)}{(B11 + B8)}; \quad (4)$$

čia B3, B4, B5, B6, B7, B8, B11 – „Sentinle-2 MSI vaizdo juostos.

$$Sigma_ratio_db = Sigma0_VV_db - Sigma0_VH_db, \quad (5)$$


čia Sigma0_VV_db ir Sigma0_VH_db – „Sentinel-1“ apdoroto SAR vaizdo juostos.

Apdoroti SAR, MSI vaizdai ir apskaičiuoti indeksai sujungiami į vieną bendrą vaizdą, naudojant ESA SNAP įrankį *Collocate*. Taip gaunamas vienas vaizdas, kuris toliau naudojamas segmentavimo procese.

Segmentuoti naudotas populiarus „Random Forest“ (toliau – RF) algoritmas (Sun et al., 2019).

Atlikus žemės dangos segmentavimą, gaunamas rastras su 6 žemės dangos klasėmis (miškai, hidrografija, smėlynai, vegetacijos plotai, augalija nepadengti plotai ir urbanizuotos teritorijos). Segmentuotas rastras yra konvertuojamas į GeoTIFF-BigTIFF formatą, kad vaizdas

neprarastų savo geolokacinės informacijos ir būtų tinkamas tolesnei analizei GIS programomis. Dažnu atveju segmentuotame žemės dangos rastre pasitaiko pavienių klaidingai segmentuotų gardelių, kurios atrodo kaip triukšmas. Tokiu atveju siūloma atlikti gardelių perklasifikavimą, kurio metu pavienėms gardelėms perduodama kitos klasės reikšmė, su kuria turi bendras keturias sienas. Dviejų skirtingų laikotarpių apdoroti ir paruošti rastrai žemės dangos pokyčiams identifikuoti konvertuojami į vektorinius duomenis. Šis žingsnis atliekamas tam, kad būtų galima pašalinti gardeles, kuriose neįvyko žemės dangos pokytis, taip paliekant tik tuos plotus, kuriuose pokytis buvo užfiksuotas. Žemės dangos klasių pokytis įvertinamas sugretinus skirtingų laikotarpių vektorinius segmentuotus žemės dangos sluoksnius. Gaunamas naujas sluoksnis, kuriame pateikti duomenys, tiksliau, žemės dangos klasių identifikatoriai, pagal kuriuos galima matyti, kokios dvi klasės buvo sujungtos (angl. *Union*). Žemės dangos pokyčių rezultato fragmentas pateiktas 3 paveiksle.



3 paveikslas. Identifikuoti žemės dangos pokyčiai, naudojant SAR ir MSI palydovinių vaizdų sintezę. Balti plotai – smėlynai, gelsvi – augalija nepadengtos teritorijos, šviesiai žali – vegetaciniai plotai, tamsiai žali – miškai, mėlyni – hidrografija, pilki – urbanizuotos teritorijos, juodi štrichai – identifikuoti žemės dangos plotai, kuriuose įvyko pokytis

Gautas 2018 ir 2019 metų žemėnaudų pokyčių vertinimo rezultatas (3 pav.) analizuotas vizualiai ir lygintas su tuo paties laikotarpio RGB palydoviniais vaizdais. Buvo atliktas kokybinis identifikuotų pokyčių tikslumo vertinimas. Tyrimo metu identifikuota 511 žemės dangos klasių pokyčių, kurie užima didesnę nei 5 ha plotą. Visose

klasių porose atsirinkta atsitiktinių 20 objektų (arba visi, jei pokyčių identifikuota mažiau) ir tikrintas jų faktinis pokytis, remiantis RGB vaizdais. 2018–2019 m. daugiausia žemės dangos pokyčių užfiksuota dviejose klasių porose, t. y. iš augalija nepadengtų žemės dangos plotų pakito į miškus ir iš vegetacinių žemės dangos plotų pakito taip pat į miškus. Mažiausiai pokyčių užfiksuota smėlynų ir hidrografijos klasėse. 6 iš 13 žemės dangos klasių porų turi šimtaprocentinį neigiamą rezultatą, tai reiškia, kad faktinis pokytis tose vietose neįvyko ir yra identifikuoti klasifikavimo nesutapimai.

Iš atlikto kokybinio tikslumo patikros galima teigti, kad dauguma identifikuotų pokyčių yra ne faktiniai pokyčiai tarp 2018 ir 2019 metų, o pokyčiai tarp netikslaus žemės dangos segmentavimo. Nepaisant to, kad, be multispektrinių duomenų, buvo naudoti ir SAR duomenys, tačiau vis tiek išliko sudėtingas vegetacinių plotų, urbanizuotų teritorijų ir augalija nepadengtų plotų klasių identifikavimas ir šių klasių tarpusavio atskyrimas.

Apibendrinimas

Atliktas segmentavimas parodė, kad, taikant kontroliuojamą segmentavimo metodą, yra sumaišomos urbanizuotų teritorijų ir augalija nepadengtų teritorijų arba urbanizuotų teritorijų ir smėlynų klasės dėl labai panašaus spektrinio „parašo“. Šie segmentavimo netikslumai vėliau identifikuojami kaip žemės dangos pokyčiai, kurie yra klaidingi ir neatitinkantys realios situacijos. Tokioms situacijoms aptikti reikalingi tolesni moksliniai tyrimai.

Kokybinė patikra parodė, kad visi klaidingai identifikuoti pokyčiai yra klaidingai teigiami rezultatai. Tai reiškia, kad tyrimo metu pokyčiai identifikuoti, tačiau jie neįvyko (arba įvyko, bet ne tarp tų klasių), bet analizuojant vaizdus nepastebėta klaidingai neigiamų rezultatų, t. y. pokyčių, kurie tyrimo metu nebuvo užfiksuoti, bet iš tikrųjų įvyko. Toks rezultatas leidžia daryti prielaidą, kad nepaisant to, jog pokyčiai identifikuoti klaidingai, tačiau jų peržiūra rankiniu būdu sunaudotų mažiau laiko išteklių nei nuosekli visos teritorijos peržiūra ir pokyčių skaitmeninimas.

Literatūra

- Barbedo, J. G. A., Romani, L. A. S., & Gonçalves, R. R. V. (2018). A Review on the Automatic Segmentation and Classification of Agricultural Areas in Remotely Sensed Images. *Embrapa Document Series*, 15. https://www.researchgate.net/publication/328073552_A_Review_on_the_Automatic_Segmentation_and_Classification_of_Agricultural_Areas_in_Remotely_Sensed_Images
- Blaschke, T., Hay, G.J., Kelly, M., Lang, S., Hofmann, P., Addink E., & Feitosa, R. Q. (2014). Geographic Object-Based Image Analysis Towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing*, 87: 180–191. <https://doi.org/10.1016/j.isprsjprs.2013.09.014>

- Open Access Hub (2021). <https://scihub.copernicus.eu/>
- Park, B., & Lu, R. (2015). *Hyperspectral Imaging Technology in Food and Agriculture*. E-book, Springer Science+Business Media LLC New York is part of Springer Science+Business Media.
- SNAP ESA Documentation. (2020). <https://step.esa.int/main/doc/>
- Sun, C., Bian, Y., Zhou, T., & Pan, J. (2019) Using of multi-source and multi-temporal remote sensing data improves crop-type mapping in the subtropical agriculture region. *Sensors*, 19(10), 1–23. <https://doi.org/10.3390/s19102401>
- Wang, S., Sun, J., Phillips, P., Zhao, G., & Zhang, Y. (2018). Polarimetric synthetic aperture radar image segmentation by convolutional neural network using graphical processing units. *Journal of Real-Time Image Process*, 15, 631–642. <https://doi.org/10.1007/s11554-017-0717-0>

SATELLITE IMAGE FUSION AND SEGMENTATION FOR LAND COVER RESEARCH

G. Metrikaitytė, J. Sužiedelytė Visockienė

Summary

The aim of this work is to evaluate the quality of the identification of changes in land cover detected in the period 2018–2019 using satellite image fusion and segmentation. The paper provides an overview of satellite image segmentation methods and their application in land cover studies using satellite image fusion. Publicly available and free of charge Sentinel-1 synthetic aperture radar and Sentinel-2 multispectral satellite images distributed by the European Space Agency were selected for the re-search. The study involved the fusion and segmentation of these images and the detection of land cover change. The article pre-sents the results and insights from the study of the changes identified in land cover and qualitative precision.

Keywords: SAR, MSI, fusion, segmentation, satellite images, land cover.