



LANDSAT TM KOSMINIŲ NUOTRAUKŲ SEGMENTAVIMO METODŲ PALYGINIMAS ATLIEKANT ŽEMĖS DANGOS KLASIFIKAVIMĄ

Jurgita Milieškaitė¹, Gediminas Vaitkus²

¹Geodezijos ir kadastro katedra, Vilniaus Gedimino technikos universitetas,
Saulėtekio al. 11, LT-10223 Vilnius, Lietuva

²Taikomųjų tyrimų centras UAB „Aerogeodezijos institutas“,
Pramonės pr. 13, LT-51327 Kaunas, Lietuva
El. paštas: ¹gkk@vgtu.lt; ²gedas@agi.lt

Įteikta 2011 06 14; priimta 2011 09 07

Santrauka. Kosminiai vaizdai yra vienas iš informacijos šaltinių apie žemės paviršiuje esančius objektus, tačiau praktiškai kosminiai vaizdai Lietuvoje naudojami dar neseniai. Pateiktas kosminio vaizdo segmentavimas taikant vieną iš skaitmeninių vaizdų klasifikavimo metodų – kontroliuojamąjį klasifikavimą (angl. *supervised classification*). Landsat TM skaitmeninio vaizdo klasifikavimas (nusistatytų klasių išskyrimas) atliktas taikant daugiaspektrius SMAP (*sequential maximum a posteriori*) ir MCL („*maximum likelihood*“ classifier) segmentavimo algoritmus geografinės informacinės sistemos GRASS (*geographic resources analysis support system* – geografinių duomenų analizės palaikymo sistema) aplinkoje. Klasifikavimo tikslumui įvertinti skaičiuota klaidų matrica (*confusion* ar *error matrix*) ir kapa koeficientas. Tyrimų duomenys rodė, kad nuotolinio stebėjimo ir GIS technika yra puiki priemonė Žemės dangos tipams identifikuoti ir plotams apskaičiuoti, tačiau aprašytaisiais metodais gautiems rezultatams įvertinti tiksliau būtini lauko tyrimai vietovėje.

Reikšminiai žodžiai: kontroliuojamasis klasifikavimas, Landsat TM skaitmeninis vaizdas, segmentavimas, žemės dangos klasifikavimas, SMAP (*a posteriori* nuoseklus maksimumas), MLC („didžiausio panašumo“ klasifikatorius).

1. Įvadas

Daugiausia duomenų apie Žemės dangą gaunama nuotoliniais metodais – iš aerofotonuotraukų ir kosminių vaizdų, kurie apdorojami ir analizuojami taikant specializuotas geoinformacines technologijas. GIS technologijų plėtojimas kraštovaizdžio stebėsenos tikslams yra susijęs su visišku proceso automatizavimu, kad sumažėtų laiko ir darbo sąnaudos bei būtų išvengta klaidų dėl specialistų patirties stokos ar subjektyvumo (Gulbinas *et al.* 2003).

Turint skaitmeninius vaizdus, informacijai apie žemės dangą išskirti galima naudoti įvairius klasifikavimo algoritmus. Skaitmeniniams vaizdams klasifikuoti naudojama vienu ar daugiau spektrinių diapazonų (kanalų) pateikta spektrinė informacija. Klasifikuojama kiekvieno vaizdo gardelė (mažiausias vaizdo elementas). Remiantis statistinėmis mažiausio vaizdo elemento šviesumo reikšmių charakteristikomis vaizdai priskiriami tam tikroms klasėms (pvz., vandenys, miškai, žemės ūkio kultūros ir kt.). Gautą klasifikuotą vaizdą sudaro mozaika iš mažiausiųjų jo elementų, kurių kiekvienas priklauso tam tikrai klasei, ir šis vaizdas yra teminis „žemėlapis“.

Išskiriami du pagrindiniai skaitmeninių vaizdų klasifikavimo metodai (Yang *et al.* 2006), kuriuose naudojamos tik skaitmeninės mažiausiųjų vaizdo elementų reikšmės ir jų santykių pasirinktuose kanaluose proporcijos:


- nekontroliuojamasis klasifikavimas (*unsupervised classification*), atliekamas statistiniais metodais. Nustatomi galimų klasių reikšmių diapazonai, nenurodant etaloninių reikšmių ir nepasirenkant klasių;
- kontroliuojamasis klasifikavimas (*supervised classification*), reikalaujama, kad operatorius parinktų Žemės dangos klasių etalonus ir pažymėtų juos tam tikrame vektoriniame sluoksnyje. Toliau klasifikavimas atliekamas automatiškai, naudojant etaloninių mažiausiųjų vaizdo elementų reikšmes. Taigi atlikus nekontroliuojamąjį klasifikavimą žemės naudmenų pobūdis nenustatomas. Tik išskiriamos skirtingos žemės naudmenos, jas identifikuoti turi operatorius.

Šiame darbe aptariamas kontroliuojamasis klasifikavimo (*supervised classification*) metodas, pagrįstas nusistatytų etaloninių vaizdo elementų reikšmių atpažinimu.

Darbo tikslas – automatiškai (kontroliuojamojo klasifikavimo metodu) sugrupuoti kosminio vaizdo mažiausiuosius elementus į numatytas žemės dangos klases (etalonus) ir nustatyti, kokią įtaką kontroliuojamosios klasifikacijos tikslumui turi kosminio vaizdo rastrinė segmentacija ir įvairūs jo parametrai.

2. Tyrimų metodika

Eksperimentiniai uždaviniai (skaitmeninių vaizdų klasifikavimas pagal pasirinktas klases) atlikti taikant *Quantum GIS* programinę įrangą kartu su geografinė informacine sistema *GRASS* (*geographic resources analysis support system*). Naudoti 1994 m. *Landsat TM* (25/06/1994) skaitmeniniai rastriniai vaizdai, kurių 30 m skiriamoji geba visai pakankama žemės naudmenoms nustatyti. *Landsat* palydovų nuotraukos apima didelę teritorijos dalį – 185x170 km. *Landsat TM* vaizdai yra iš didesnio spektrinių kanalų skaičiaus nei kitų plačiai naudojamų Žemės išteklių palydovinio ryšio sistemų (pvz., *SPOT*, turinčios keturis kanalus) (Jensen 2000). Derinant skirtingus kanalus gaunami skirtingos raiškos (spalvų) vaizdai. Šiuo atveju žemės naudmenoms identifikuoti (išskirti) regimai pasirinktas multispektrinis vaizdas, susidedantis iš trijų spektrinių kanalų (4-ojo, 5-ojo ir 3-ojo), t. y. raudonos spalvos spektras – 0,76–0,90 μm; žalios – 1,55–1,75 μm; mėlynos – 0,63–0,69 μm (Moran *et al.* 2002; Candade, Barnali 2004). Šių kanalų derinys pakankamai gerai padeda išgauti informaciją apie regimąją Žemės dangą (naudmenas) (1 pav.).



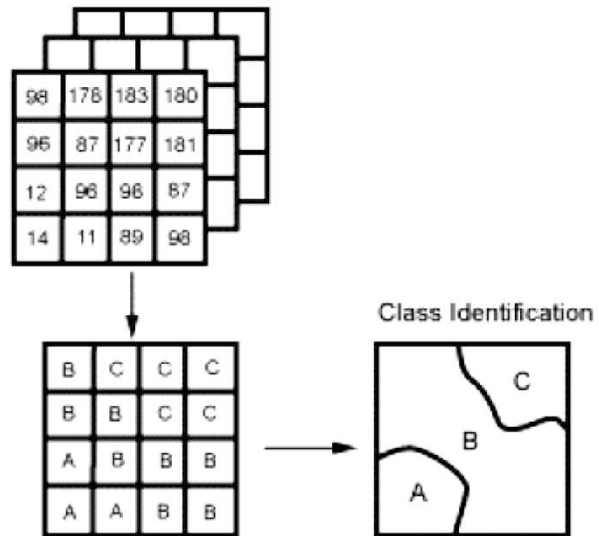
1 pav. Landsat TM vaizdas iš 4, 5 ir 3 kanalų derinio
 Fig. 1. Landsat TM image from the combination of the 4, 5 and 3 channels

Quantum GIS (*QGIS*) programinės įrangos aplinkoje *Landsat TM* vaizdo Žemės paviršiaus dangos plotai (pagal spalvas) priskiriami (nusistatomi) atitinkamai pagal klasę: 1 – pelkės; 2 – lapuočių miškas; 3 – vanduo; 4 – krūmai; 8 – durpynas; 9 – spygliuočių miškai; 10 – pieva; 11 – apleisti laukai; 20 – paviršius be augalijos. Šiuo atveju reikia teisingai dešifruoti plotus, kuriuose yra dominančios klasės (žemės naudmenos). Norint tinkamai pasirinkti plotus (etaloninių vaizdo elementų reikšmes) reikia rinktis kuo homogeniškesnę žemės paviršiaus dangos

dalį *Landsat TM* vaizde. Tik pagal nurodytas klases toliau bus atliekamas klasifikavimas, t. y. vaizdo mažiausieji elementai bus priskirti vienai iš nurodytų klasių.

Gautų rezultatų tikslumas priklauso nuo nurodytų klasių skaičiaus, parinktos homogeniškesnės Žemės paviršiaus dalies. Apsiribojant nedideliu klasių skaičiumi rezultatai nebus tokie tikslūs (Neteler 1997), nes Žemės paviršiaus sudėtis pagal žemės naudmenų rūšis įvairi.

Toliau *GRASS* informacine sistema nustatomos skaitmeninės spektrinės kiekvienos klasės statistikos (diapazonai, užsienio literatūroje vadinamos *signature*), (Candade, Barnali 2004; Lu *et al.* 2004; Shportyuk *et al.* 2006). Matuodami žemės paviršiaus objektų atspindėtą (ar spinduliuojamą) įvairaus bangų ilgio energiją galime sudaryti to objekto spektrinį apibūdinimą. Spektrinio atspindžio struktūros vadinamos spektrinėmis statistikomis. Kiekviena vaizdo gardelė lyginama su šiomis spektrinėmis statistikomis ir pažymima kaip priklausanti tai klasei, kurią skaitinėmis reikšmėmis labiausiai „primena“. Šio klasifikavimo schema (principas) pateikiama 2 paveiksle.

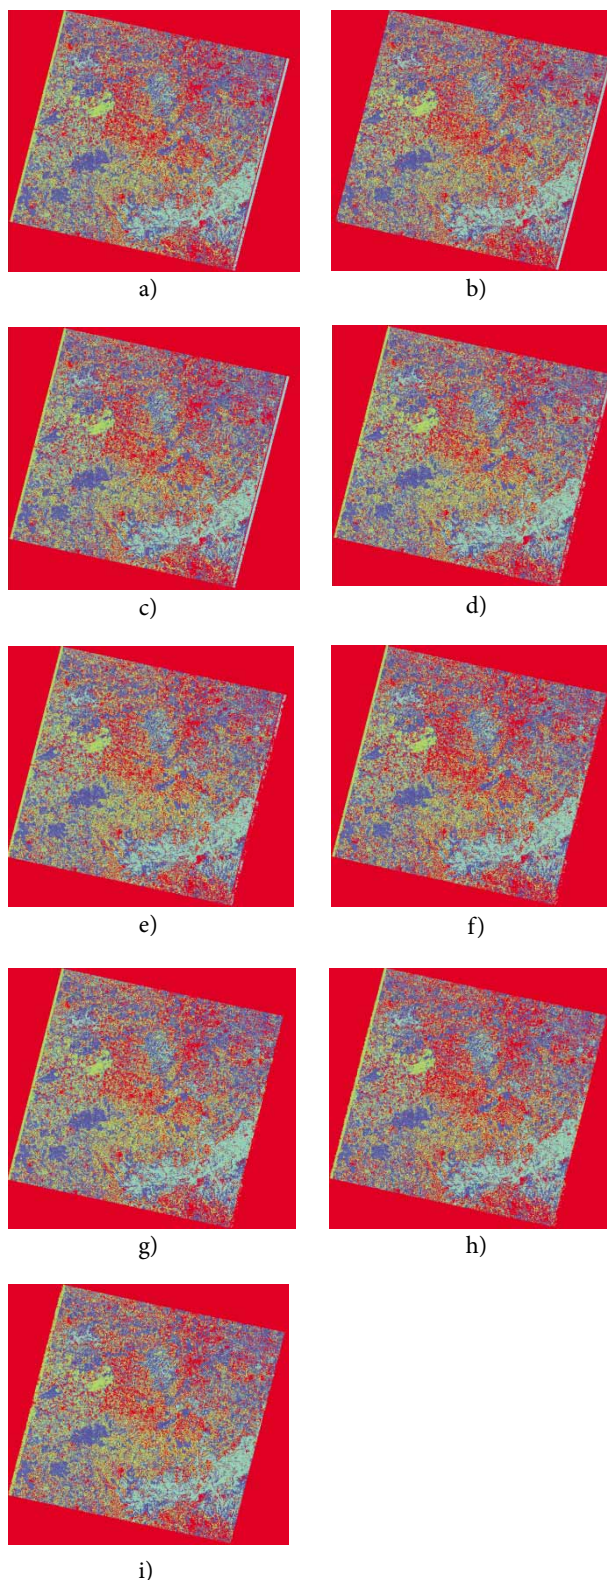


2 pav. Kontroluojamojo klasifikavimo schema
 Fig. 2. Scheme of the controlled classification

GRASS informacine sistema klasifikavimas atliktas taikant daugiaspektrius *SMAP* (*sequential maximum a posteriori*) ir *MCL* („*maximum likelihood*“ classifier) segmentavimo algoritmus.

3. Rezultatai ir jų analizė

Taikant *SMAP* segmentavimo algoritmą (*GRASS* modulis *i.gensigset*) nustatoma kiekvienos klasės spektrinė statistika. Kiekvienos klasės spektrinės statistikos reikšmės nustatytos devyniuose poklasiuose. Kiekvienas poklasis turi skirtingų skiriamųjų spektrinių charakteristikų. Kiekvieną poklajį apibūdina tam tikri parametrai ir spektrinis variacijos sudedamųjų dalių rinkinys (Shapiro *et al.* 1994). Su nustatytais spektrinėmis statistikos reikšmėmis toliau (*i.smmap* modulis) buvo lyginamas kiekvienas mažiausias vaizdo elementas ir priskiriamas tam tikrai klasei. Gautas suklasifikuotas vaizdas (Neteler 1997) (3 pav.).



3 pav. SMAP segmentuojant suklasifikuoti Žemės dangos vaizdai naudojant vieną (a), du (b), tris (c), keturis (d), penkis (e), šešis (f), septynis (g), aštuonis (h), devynis (i) poklasius


Fig. 3. Classified land cover images by SMAP segmentation process and using one (a), two (b), three (c), four (d) five (e), six (f), seven (g), eight (h), nine (i) subclasses

Gautų suklasifikuotų vaizdų skirtumas sunkiai pastebimas, tačiau apskaičiavus (taikant *r.report* modulį) suklasifikuotuose vaizduose gautų klasių plotus skirtumas akivaizdus. Žemės dangos klasių plotai ir bendras suklasifikuoto vaizdo plotas pateikti 1 lentelėje. Gautų plotų skirtumai grafiškai pavaizduoti 4 paveiksle.

Iš 1 lentelės ir 4 pav. matyti, kad klasių plotai į skirtingus poklasius suklasifikuotuose vaizduose skiriasi. Ryškiausias skirtumas pastebimas į vieną poklasį suklasifikuotame vaizde ir būtent šių klasių: 20 (paviršius be augalijos), 8 (durpynas) ir 11 (apleisti laukai). Kitų klasių plotų skirtumai nėra tokie ryškūs, tačiau pažymėtina, kad didžiausi plotų skirtumai į skirtingus poklasius suklasifikuotų vaizdų yra 8 klasės (durpynas) – iki 60 % (neatsižvelgus į vieną poklasį suklasifikuotame vaizde apskaičiuotą 8 klasės plotą, kuris ypač skiriasi (3 pav.)), o mažiausi – 2 klasės (lapuočių miškas) (iki 98 %), 3 (vanduo) (iki 99 %) ir 9 klasės (spygliuočiai miškai) (iki 98 %). Jei neatsižvelgtume į vieną poklasį suklasifikuotame vaizde apskaičiuotą 20 klasės (paviršius be augalijos) plotą, šios klasės plotų skirtumai 3 paveiksle pateiktuose (b–i) vaizduose būtų taip pat nedideli (98 %).

Siekiant tiksliai įvertinti apskaičiuotų plotų tikslumą (patikimumą) būtina turėti lauko matavimo (vietovėje atlikto) duomenis, su kuriais būtų galima palyginti suklasifikuotus vaizdus (identifikuotą Žemės paviršį) bei apskaičiuotus klasių plotus.

Toliau taikant *MLC* segmentavimo algoritmą nustatomos (*GRASS* modulis *i.gensig*) kiekvienos klasės spektrinės statistikos. Jas pasirinkę nustatėme kaip vieną – septynis ir devynis poklasius. Su nustatytomis spektrinėmis statistikomis kiekvienas mažiausias vaizdo elementas lyginamas taikant *i.maxlik* modulį ir pažymimas kaip priklausantis tam tikrai klasei. Šiuo atveju (*i.maxlik* modulis) klasifikacija atliekama pagal didžiausios tikimybės algoritmą (Neteler 1997). Segmentuojant *MLC* suklasifikuoti vaizdai pateikti 5 paveiksle, identifikuotų klasių plotai ir bendras klasių plotas suklasifikuotame vaizde – 2 lentelėje. Gautų plotų skirtumai grafiškai pavaizduoti 6 paveiksle.



4 pav. I SMAP segmentavimo algoritmu suklasifikuotų vaizdų apskaičiuoti klasių plotai pavaizduoti grafiškai

Fig. 4. Graphical representation of the areas of classes of classified images by SMAP algorithm

1 lentelė. Pasirinkus skirtingus poklasius SMAP suklasifikuotų vaizdų klasių plotai (ha)


Table 1. Areas of classes of classified images by SMAP and choosing different subclasses

Klasės	Poklasiai									Vidutinis plotas, ha
	1	2	3	4	5	6	7	8	9	
1	35,37	31,96	28,08	29,93	32,00	34,42	29,93	32,37	33,05	31,90
2	601,94	563,69	632,36	606,24	610,34	604,42	613,26	596,51	610,98	604,41
3	67,85	68,85	72,46	70,05	69,20	69,68	68,65	68,76	69,12	69,40
4	526,66	616,42	614,84	629,66	566,59	547,20	592,44	577,32	574,63	582,86
8	1983,30	53,54	51,64	29,35	24,53	15,29	13,39	12,84	11,01	243,88
9	317,74	331,44	323,19	337,72	332,80	338,61	340,42	344,30	340,34	334,06
10	102,01	115,86	141,40	130,41	124,56	127,44	132,37	131,41	117,09	124,73
11	552,43	913,84	905,32	980,39	1008,11	898,89	979,66	877,02	981,64	899,70
20	1330,14	2821,85	2748,17	2703,69	2749,32	2881,48	2747,33	2876,90	2779,57	2626,50
Iš viso:	5517,44	5517,44	5517,44	5517,44	5517,44	5517,44	5517,44	5517,44	5517,44	5517,44

2 lentelė. Pasirinkus skirtingus poklasius MLC suklasifikuotų vaizdų apskaičiuotieji klasių plotai


Table 2. Areas of classes of classified images by MLC and choosing different subclasses

Klasės	Poklasiai								Vidutinis plotas, ha
	1	2	3	4	5	6	7	9	
1	53,87	49,79	46,33	49,56	32,00	52,13	49,46	51,18	48,04
2	581,14	551,69	606,78	583,25	610,34	581,40	585,59	590,85	586,38
3	67,93	69,03	72,58	69,66	69,20	69,59	68,43	69,04	69,43
4	537,23	601,41	617,75	614,29	566,59	581,35	613,38	612,00	593,00
8	1988,04	57,55	56,78	35,77	24,53	20,94	19,51	16,81	277,49
9	325,38	338,75	329,37	342,32	332,80	342,85	340,88	340,89	336,66
10	154,40	180,79	236,72	214,13	124,56	220,68	220,30	202,77	194,29
11	613,67	806,10	784,80	874,84	1008,11	850,44	895,09	891,08	840,52
20	1195,78	2862,34	2766,33	2733,63	2749,32	2798,06	2724,79	2742,82	2571,63
Iš viso:	5517,44	5517,44	5517,44	5517,44	5517,44	5517,44	5517,44	5517,44	5517,44



5 pav. Segmentuojant MLC suklasifikuoti Žemės dangos vaizdai taikant vieną (a), du (b), tris (c), keturis (d), penkis (e), šešis (f), septynis (g), devynis (h) poklasius

Fig. 5. Classified land cover images by MLC segmentation process and using one (a), two (b), three (c), four (d) five (e), six (f), seven (g), eight (h), nine (i) subclasses




6 pav. Iš MLC segmentavimo algoritmu suklasifikuotų vaizdų apskaičiuoti klasių plotai pavaizduoti grafiškai

Fig. 6. Graphical representation of the areas of classes of classified images by MLC algorithm

Iš 2 lentelės ir 6 pav. matyti, kad klasių plotai į skirtingus poklasius suklasifikuotuose vaizduose taip pat skiriasi. Šiuo atveju ryškiausias skirtumas pastebimas taip pat į vieną poklasį suklasifikuotame vaizde ir taip pat 20 klasės (paviršius be augalijos), 8 (durpynas), 11 (apleisti laukai) ir papildomos 10 klasės (pieva). Dar šiek tiek ryškesnis skirtumas pastebimas į penkis poklasius suklasifikuotuose vaizduose 10 klasės (pieva) ir 11 klasės (apleisti laukai). Beje, pažymėtina, kad didžiausi plotų skirtumai į skirtingus poklasius suklasifikuotuose vaizduose nustatyti vėl 8 klasės (durpynas) – iki 65 % (nepaisant į vieną poklasį suklasifikuotame vaizde apskaičiuoto 8 klasės ploto, kuris ypač skiriasi (6 pav.)), o mažiausi – 2 klasės (lapuočių miškas) (iki 98 %), 3 (vanduo) (iki 99 %) ir 9 (spygliuočiai miškai) (iki 98 %).

4. Tikslumo vertinimas

Vienas iš svarbiausių kontroliuojamos klasifikacijos etapų yra tikslumo vertinimas, kai klasifikavimo rezultatai, siekiant statistiškai įvertinti rezultatų kokybę, tikrinami pagal tam tikrus kriterijus. Šiuo atveju vertinta, ar kosminio vaizdo mažiausieji elementai SMAP ir MCL segmentavimo algoritmu tinkamai sugrupuoti į nusistatytas Žemės dangos klases. Klasifikavimo rezultatai buvo vertinami pagal susikurtą kontrolinių taškų sluoksnį (žr. 7 pav.).



7 pav. Landsat TM vaizde sukurtas kontrolinių taškų sluoksnis

Fig. 7. Layer of the control points in the Landsat TM image

Kiekvienam kontroliniam taškui, kurių yra 500, atsižvelgiant į jų padėtį Landsat TM skaitmeniniame rastriniame vaizde, rankiniu būdu priskirtas atitinkamos klasės numeris. Šiai procedūrai atlikti būtina operatoriaus (specialisto) patirtis bei įgūdžiai identifikuojant Žemės dangą (naudmeną) iš Landsat TM skaitmeninio vaizdo. Nuo to, kaip tiksliai bus atpažinta žemės danga ir kontroliniams taškams suteiktas klasės numeris, priklauso tikslumo įvertinimas.

Toliau tiems patiems kontroliniams taškams, atsižvelgiant į jų vietą (į kurią klasę pateko), automatiškai QGIS programa skiriamas atitinkamas klasės numeris suklasifikuotuose vaizduose (3–5 pav.).

Iš esmės kontrolinio taško klasės numeris – ir nustatytas rankiniu būdu iš Landsat TM skaitmeninio rastrinio vaizdo, ir automatiškai iš skirtinguose poklasiuose suklasifikuotų vaizdų, turėtų sutapti. 3 lentelėje pateikti kontrolinių taškų klasių numerių, kurie buvo priskirti operatoriaus rankiniu būdu iš Landsat TM skaitmeninio vaizdo ir automatiškai QGIS programa iš skirtinguose poklasiuose suklasifikuotų vaizdų, sutapimo duomenys. Matyti, kad klasių numerių sutapimo procentas svyruoja nuo 75 % iki 81 %, taikant SMAP segmentavimo algoritmą, ir nuo 72 % iki 76 %, taikant MLC segmentavimo algoritmą. Darytina išvada, kad didesnis sutapimo procentas yra taikant SMAP segmentavimo algoritmą.

3 lentelė. Kontrolinių taškų klasių numerių, priskirtų iš Landsat TM skaitmeninio vaizdo ir iš skirtinguose poklasiuose suklasifikuotų vaizdų, sutapimo procentas

Table 3. Percentage of the coincidence of the control points class numbers, assigned in the Landsat TM digital image and assigned in the images, classified according to different subclasses

Poklasių skaičius	Taikant SMAP segmentavimo algoritmą		Taikant MLC segmentavimo algoritmą	
	kontrolinių taškų, kuriuose klasės nesutampa, skaičius	sutapimo procentas	kontrolinių taškų, kuriuose klasės nesutampa, skaičius	sutapimo procentas
1	93	81,40 %	118	76,40 %
2	119	76,20 %	136	72,80 %
3	123	75,40 %	137	72,60 %
4	118	76,40 %	136	72,80 %
5	110	78 %	137	72,60 %
6	109	78,20 %	122	75,60 %
7	116	76,80 %	128	74,40 %
8	114	77,20 %		
9	115	77 %	124	73,60 %
Vidurkis		77,40 %		73,85 %

Pagal kontroliniuose taškuose priskirtų klasių rezultatus (klasių numerių sutapimus) toliau skaičiuota klaidų matrica (confusion ar error matrix), kuri dažniausiai naudojama klasifikavimo tikslumui nustatyti (Congalton 1991; Foody 2002). Skačiuojant gautas kiekvienos klasės nustatymo procentas į skirtingus poklasius suklasifikuotuose vaizduose. Rezultatai, gauti taikant SMAP segmentavimo algoritmą, pateikti 4 lentelėje, o MLC segmentavimo algoritmu – 5 lentelėje.

4 lentelė. Klasių identifikavimo procentas, taikant SMAP segmentavimo algoritimą

Table 4. Percentage of the classes identification applying SMAP segmentation algorithm

Klasės	Poklasiai									Vidurkis
	1	2	3	4	5	6	7	8	9	
1	75 %	75 %	75 %	80 %	80 %	80 %	80 %	80 %	80 %	78 %
2	86 %	87 %	82 %	88 %	87 %	84 %	87 %	85 %	86 %	86 %
3	100 %	100 %	100 %	100 %	100 %	100 %	100 %	100 %	100 %	100 %
4	59 %	54 %	55 %	56 %	60 %	57 %	59 %	61 %	59 %	58 %
8	67 %	100 %	100 %	100 %	100 %	100 %	100 %	100 %	100 %	96 %
9	97 %	92 %	93 %	91 %	92 %	91 %	92 %	91 %	91 %	92 %
10	67 %	60 %	52 %	52 %	64 %	68 %	59 %	60 %	65 %	61 %
11	71 %	62 %	57 %	60 %	58 %	62 %	57 %	58 %	58 %	60 %
20	85 %	82 %	90 %	87 %	91 %	90 %	88 %	86 %	87 %	87 %
Vidurkis	79 %	79 %	78 %	79 %	81 %	81 %	80 %	80 %	81 %	

5 lentelė. Klasių identifikavimo, taikant MLC segmentavimo algoritimą, procentas

Table 5. Percentage of the classes identification applying MLC segmentation algorithm

Klasės	Poklasiai									Vidurkis
	1	2	3	4	5	6	7	9		
1	50 %	50 %	100 %	60 %	60 %	75 %	75 %	75 %	68 %	
2	82 %	80 %	80 %	80 %	81 %	80 %	83 %	81 %	81 %	
3	100 %	100 %	100 %	100 %	100 %	100 %	100 %	100 %	100 %	
4	52 %	47 %	53 %	52 %	61 %	56 %	56 %	57 %	54 %	
8	25 %	100 %	67 %	100 %	50 %	67 %	100 %	67 %	72 %	
9	94 %	91 %	89 %	89 %	89 %	89 %	89 %	89 %	90 %	
10	42 %	43 %	38 %	39 %	39 %	41 %	47 %	47 %	42 %	
11	69 %	63 %	54 %	57 %	51 %	63 %	56 %	58 %	59 %	
20	86 %	80 %	87 %	87 %	88 %	89 %	86 %	88 %	86 %	
Vidurkis	67 %	73 %	74 %	74 %	69 %	73 %	77 %	74 %		

Iš 4 ir 5 lentelių matyti, kad Žemės dangos tipai geriausiai buvo klasifikuoti taikant SMAP segmentavimo algoritimą. Ypač gerai identifikuota 3 klasė (vandenys) iki 100 %, 8 (durpės) – iki 96 % bei 9 (spygliuočiai miškai) – iki 92 %. Prasčiausiai identifikuota 4 klasė (krūmų plotai) – iki 58 %. Pažymėtina, kad krūmų plotus apibūdinanti Landsat TM vaizdo mažiausiojo elemento (šviesumo) reikšmė artima reikšmei, kuri nusako pievų plotus (10 klasė). Galimas dalykas, jog operatorius rankiniu būdu priskirdamas kontroliniams taškams klasės numerį krūmų plotus Landsat TM vaizde identifikavo kaip pievų plotus arba atvirkščiai. Šiuo atveju, siekiant tikslesnių rezultatų, būtina atlikti tyrimus vietovėje, t. y. nustatyti, ar Landsat TM vaizde dešifruotos (nustatytos) žemės naudmenos sutampa su žemės naudmenomis, esančiomis vietovėje.

Žinoma, kad SMAP segmentavimo algoritmas generuoja vidutiniškai didžiausius plotinius objektus, nes šis algoritmas sukuria mažiau objektų, kurių vaizdo mažiausiųjų elementų skaičius nedidelis (Shapiro *et al.* 1994). Iš 4 lentelės matyti, kad geriausi rezultatai pasiekti į 5, 6 ir 9 poklasius suklasifikuotuose vaizduose.

Klasifikavimo tikslumas įvertintas pagal kappa koeficientą (Bektas 2003; Kamaruzaman, Mohd Hasmadi 2009), kuris taikomas tada, kai abiejų kintamųjų kategorijų reikšmės tos pačios, ir vienodas kategorijų skaičius. Kappa koeficientas yra statistinis matas, šiuo atveju taikomas dviem klasifikavimo metodais gautiems rezultatams palyginti (Senseman *et al.* 1995). Jis apskaičiuojamas taip:

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} x_{+i})}$$

čia r – klaidų matricos eilučių ir stulpelių numeris; N – bendras lyginamų kontrolinių taškų skaičius; x_{ii} – taškų i -toji eilutė ir i -tasis stulpelis; x_{i+} – bendras eilutės skaičius; x_{+i} – bendras stulpelių skaičius.

Kappa koeficiento reikšmės svyruoja nuo 1,0 iki -1,0. Tikslumui įvertinti jos skirstomos į tris kategorijas: visiškasis atitikimas (1,0-0,8), vidutinis (geras) atitikimas (0,8-0,4) ir prastas atitikimas (0,4-0,0) (Landis, Koch 1977).

6 lentelė. Kontrolinių taškų atitikimas**Table 6.** Coincidence of the control points

Kappa koefic.	Poklasiai									Vidurkis
	1	2	3	4	5	6	7	8	9	
k (SMAP)	0,71	0,71	0,70	0,71	0,73	0,74	0,72	0,72	0,74	0,73
k (MLC)	0,71	0,67	0,67	0,67	0,67	0,70	0,69	–	0,70	0,69

Kappa koeficiento reikšmė lygi 1 rodo puikius tyrimo rezultatus, o –0 ir mažiau – labai prastus rezultatus. Šiuo atveju apskaičiuotos kappa koeficiento reikšmės pateiktos 6 lentelėje. Iš lentelės matyti, kad vidutinis kappa koeficientas, taikant *SMAP* segmentavimo algoritmą, yra 0,73, jis yra didesnis nei vidutinis kappa koeficientas (0,69) taikant *MLC* segmentavimo algoritmą. Kappa koeficientas 0,73 reiškia gerą tyrimo patikimumą.

5. Išvados

Pateikti kosminio vaizdo segmentavimo metodai, skirti žemės dangai iš *Landsat TM* skaitmeninio rastrinio vaizdo identifikuoti.

Landsat TM skaitmeninio rastrinio vaizdo mažiausieji vaizdo elementai sugrupuoti į pasirinktas devynias klases taikant *SMAP* ir *MCL* segmentavimo algoritmus. Geriausi rezultatai pasiekti taikant *SMAP* segmentavimo algoritmą ir 5, 6 bei 9 poklasius.

Vaizdo klasifikavimo rezultatai parodė, kad taikant *SMAP* segmentavimo algoritmą ypač gerai identifikuoti vandenių (100 %), durpių (96 %) bei spygliuočių miškų (92 %) plotai.

Apskaičiuotos koreliacijos (kappa) koeficiento reikšmės. Vidutinė koreliacijos koeficiento reikšmė, taikant *SMAP* segmentavimo algoritmą, gauta 0,73, o taikant *MLC* segmentavimo algoritmą – 0,69. Tai reiškia gerą tyrimo patikimumą.

Iš tyrimo akivaizdu, kad nuotolinio stebėjimo ir GIS technika yra puiki priemonė žemės dangos tipams identifikuoti ir jų plotams skaičiuoti, tačiau, siekiant tiksliau įvertinti aprašytaisiais metodais gautus rezultatus, būtini lauko tyrimai vietovėje.

Literatūra

- Bektas, F. 2003. *Remote sensing and geographic information integration: a case study*. Bozcaada and Gokceada Island. Msc Thesis, Institution of Science and Technology, Istanbul Technical University.
- Candade, N.; Barnali, D. 2004. Multispectral classification of Landsat images: a comparison of support vector machine and neural network classifiers, in *ASPRS Annual Conference Proceedings*, Denver, Colorado.
- Congalton, R. G. 1991. A review of assessing the accuracy of classifications of remotely sensed data, *Remote Sensing of Environment* 37: 35–46 doi:10.1016/0034-4257(91)90048-B

- Foody, G. M. 2002. Status of land cover classification accuracy assessment, *Remote Sensing of Environment* 80: 185–201. doi:10.1016/S0034-4257(01)00295-4
- Gulbinas, Z.; Pileckas, M.; Petravičiūtė, R. 2003. Kraštovaizdžio monitoringo organizavimo problematika, *Geografijos metraštis* 36(1): 225–235.
- Jensen, J. R. 2000. *Remote sensing of the environment: an Earth resource perspective*. Upper Saddle River, New Jersey: Prentice-Hall. 544 p.
- Kamaruzaman, J.; Mohd Hasmadi, I. 2009. Mapping and Quantification of Land Area and Cover Types with Landsat in Carey Island, Selangor, Malaysia, *Modern Applied Science* 3(1): 42.
- Landis, J.; Koch, G. 1977. The Measurement of Observer Agreement for Categorical Data, *Biometrics* 33: 159–174. doi:10.2307/2529310
- Lu, D.; Mausel, P.; Brondizio, E.; Moran, E. 2004. Relationships between forest stand parameters and Landsat TM spectral responses in the Brazilian Amazon Basin, *Forest Ecology and Management* 198: 149–167. doi:10.1016/j.foreco.2004.03.048
- Moran, M. S.; Hymer, D. C.; Qi, J. G.; Kerr, Y. 2002. Comparison of ERS-2 SAR and Landsat TM imagery for monitoring agricultural crop and soil conditions, *Remote Sens. Environ.* 79: 243–252. doi:10.1016/S0034-4257(01)00276-0
- Neteler, M. 1997. *Introduction to GRASS GIS Software*. Institute of Physical Geography and Landscape Ecology, University of Hannover, Germany.
- Senseman, G. M.; Bagley, C. F.; Tweddle, S. A. 1995. *Accuracy Assessment of the Discrete Classification of Remotely Sensed Digital Data for Landcover Mapping*. US Army Corps of Engineers Construction Engineering Research Laboratories. USACERL Technical Report EN-95/04.
- Shapiro, M.; Bouman, C.; Bagley, C. F. 1994. *A Multiscale Random Field Model for Bayesian Image Segmentation*. Technical Report (TR) EC-94/21/ADA283875 (U.S. Army Construction Engineering Research Laboratory [USACERL]).
- Shportyuk, Z. M.; Sakhatsky, A. I.; Sibirtseva, O. N. 2006. Land cover classification in Ukrainian carpathians using the MERIS Terrestrial Chlorophyll Index and red edge position from Envisat MERIS data, in *Proceedings of the ISPRS mid-term symposium 2006 on Remote sensing: from pixels to processes*, Enschede, the Netherlands [CD Rom].
- Yang, Y.; Lohmann, P.; Heipke, C. 2006. Genetic Algorithms for the Unsupervised Classification of Satellite Images, *IntArchPhRS XXXVI/3*: 179–184.

Jurgita MILIEŠKAITĖ. Doctoral student at the Department of Geodesy and Cadastre, Vilnius Gediminas Technical University, Saulėtekio al. 11, LT-10223 Vilnius, Lithuania. Ph +370 5 274 4703, Fax +370 5 274 4705, e-mail: *gkk@vgtu.lt*.

A graduate from Vilnius Gediminas Technical University (Master of Science, 2008).

Research interests: the clusteric correlation analysis of land cover digital raster images.

Gediminas VAITKUS. Dr. Applied Research Center, Institute of Aerial Geodesy, Pramonės pr. 13, LT-51327 Kaunas, Lithuania. Ph +370 3 745 1504, Fax +370 3 745 1404, e-mail: *gedas@agi.lt*.

Doctor's degree at VU 1999.

Research interests: ecology, environmental engineering, geoinformation systems.