

AUTOMATSKA KLASIFIKACIJA SATELITSKIH SNIMKI OBLAKA UZ PRIMJENU SEGMENTACIJE

Segmentation based automatic classification of satellite clouds images

MLADEN VIHER

Laboratorij za daljinska istraživanja, Ilica 242, Zagreb, Hrvatska

Primljeno: 5. svibnja 1998, u konačnom obliku 22. lipnja 1998.

Sažetak: Meteorološke satelitske snimke poboljšane kvalitete i bogatijeg sadržaja nameću potrebu za njihovom automatskom klasifikacijom budući da taj materijal po svojim značajkama nadmašuje čovjekove mogućnosti percepcije. Za obradu meteorološkog satelitskog materijala mogu se koristiti metode statističke klasifikacije, a cilj rada bio je pokazati kako tome može znatno doprinijeti segmentacija prije klasifikacije ili poslije nje. U prvom primjeru korištena je snimka satelita Meteosat 5 na kojoj su linearnim preslikavanjem segmentirani oblaci, a potom je klasificirana ISODATA-klasteringom. U drugom primjeru snimka satelita NOAA 14 dobivena senzorom AVHRR klasificirana je Mahalanobisovim klasifikatorom i potom je segmentirana postavljanjem granične vrijednosti na χ^2 -razdiobi Mahalanobisovih udaljenosti. U oba slučaja segmentacija je bitno doprinijela interpretabilnosti klasificirane snimke.

Ključne riječi: meteorološka satelitska snimka, segmentacija, statistička klasifikacija

Abstract: Meteorological satellite images with improved quality and more content lead to their automatic classification because characteristics of this material are beyond human perception abilities. Methods of statistical classification could be used for meteorological satellite image processing. Goal of this work was to show significant contribution of segmentation before and after classification. Meteosat 5 image was used in the first example where linear mapping segmented clouds before ISODATA clustering was applied. In the second example NOAA 14 satellite image acquired by AVHRR sensor was classified with Mahalanobis classifier and later segmented through determination of limitation value in χ^2 distribution of the Mahalanobis distances. Segmentation significantly contributed to interpretability of classified images in both cases.

Key words: meteorological satellite images, segmentation, statistical classification

1. UVOD

Automatska klasifikacija meteoroloških satelitskih snimki postaje nužan korak koji prethodi interpretaciji zbog velikih mogućnosti koje pružaju suvremeni satelitski senzori, a koje uvelike nadmašuju mogućnosti našeg osjetila vida i sposobnosti percepcije (Bankert, Aha, 1996). U radu su korištene satelitske snimke dva suvremena meteorološka satelita: Meteosat 5 i NOAA Polar Orbiter (senzor AVHRR¹). Satelitske snimke nadmašuju osjet vida po nekoliko značajki:

a) Oko razlikuje samo 12-24 razine sivila, a sateliti imaju senzore koji razlikuju 256 (npr. Meteosat) ili čak 1024 (AVHRR) razina spektralne radijance. Zbog toga nismo u stanju iskoristiti svu informaciju koja se inače nalazi na satelitskoj snimci u sivoj skali. Taj nedostatak možemo djelimično otkloniti prikazom jednokanalne slike u pseudokoloru budući da je oko u stanju razlikovati preko 10 milijuna boja.

1 Advanced Very High Resolution Radiometer

- b) Osjet vida razlikuje samo tri osnovne boje, a satelitski senzori imaju više od tri kanala. Zato se kod interpretacije multispektralne slike uvijek trebamo odlučiti koja ćemo tri kanala promatrati. U skoroj budućnosti očekuje se primjena hiperspektralnih senzora s više od 16 kanala (npr. HIRIS² s čak 192 kanala). Interpretacija takve snimke bit će moguća samo automatskom klasifikacijom.
- c) Obim i protok podataka u suvremenoj istraživačkoj i operativnoj praksi postali su toliki da za klasičnu interpretaciju satelitske snimke nema više dovoljno vremena.

To nužno vodi na statističku obradu meteorološke satelitske snimke i izdvajanje klasa automatskim postupcima.

Sateliti Meteosat 5 i NOAA/AVHRR se po svojim značajkama bitno razlikuju. Zbog toga je tijekom predložene obrade drugačiji. U priloženoj tablici dani su osnovni tehnički podaci satelita i njihovih senzora:

Prema podacima iz tablice 1 vidimo da je slikovni materijal dobiven sensorima na satelitima Meteosat 5 i NOAA/AVHRR različite kvalitete, što uvjetuje izbor statističkih metoda klasifikacije kojim ćemo ih obrađivati (Kidwell, 1995). Za klasifikaciju Meteosatove snimke koristili smo algoritam ISODATA (klasifikacija bez nadzora), dok smo za bolju AVHRR snimku koristili Mahalanobisov klasifikator, postupak klasifikacije pod nadzorom za koji je potrebno izdvojiti uzorak za učenje. Pored navdenih podataka va-

žan utjecaj na odluku o metodi klasifikacije ima i globalno pokriće geostacionarnih satelita na čijim snimkama imamo dijelove s bitno različitim i nestacionarnim satelitskim i Sunčevim zenitnim kutevima, što bitno utječe na iradijancu i time na težak odabir uzoraka za učenje (Schraeder, Pouncey, 1997).

Statistička klasifikacija satelitskih snimki standardan je oblik obrade prije interpretacije za operativne ili istraživačke potrebe. Ono što želimo pokazati jest prednost koju pruža segmentacija prije klasifikacijskog postupka ili poslije njega. Segmentacija je postupak digitalne obrade slike na srednjoj razini koji se, prema našim saznanjima, do sada nije kombinirao s postupcima digitalne obrade slike na visokoj razini kao što je klasifikacija. Segmentacija je vrlo fleksibilan postupak i priloženi primjeri nisu jedina moguća rješenja (Viher, 1995).

2. SEGMENTACIJA PRIJE KLASIFIKACIJSKOG POSTUPKA

Primjer segmentiranja slike prije klasifikacije bez nadzora proveden je na snimkama satelita Meteosat 5 u dva kanala; vidljivom do bliskom infracrvenom i toplinskom. Kao primjer uzeta je snimka napravljena 24.12.1995. godine koja prikazuje veliku ciklonu s frontalnim sustavima iznad Evrope.

Tablica 1. Usporedne tehničke značajke satelita Meteosat 5 i NOAA/AVHRR

Table 1 Compared technical characteristics of satellites Meteosat 5 and NOAA/AVHRR

	Meteosat 5	NOAA/AVHRR
Visina kruženja	36.000 km (geostacionarni)	830 km (polarno-orbitirajući)
Prostorna rezolucija	4 km (Evropa, VIS, IR) 8 km (Evropa, VW)	1.1 km
Radiometrijska rezolucija	srednja: 255 razina signala	visoka: 1024 razine signala
Spektralna rezolucija	slaba: 3 široka kanala	dobra: 5 uskih kanala
Vremenska rezolucija	velika: 2 snimke na sat	srednja: 2 snimke na dan

Na satelitskom kompozitu sastavljenom od snimki 1 i 2 nalazi se, osim oblaka, koji su objekti što nas zanimaju, još i prostorna razdioba radijance s površine koju ćemo segmentacijom ukloniti sa snimke. Radijanca s površine generirala bi, bez segmentacije, velik broj klasa vezanih za objekte i pojave na površini koji nisu u ovom slučaju predmet našeg interesa i jako otežavaju interpretaciju.

Segmentaciju ćemo provesti funkcijom linearnog preslikavanja histograma na snimkama u vidljivom i infracrvenom dijelu spektra koristeći činjenicu da je radijanca oblaka vrlo velika u vidljivom i bliskom infracrvenom dijelu spektra, dok je u toplinskom dijelu spektra mala (Lipovšćak, 1986). Po tim fizičkim značajkama oblaci će se razlikovati u kontekstu općeg sadržaja slike.

Označimo,

$h_i(x)$, histogram na izvornim snimkama

$h_0(y)$, modificirani histogram, dobiven nakon funkcije preslikavanja i

$y=f(x)$, funkciju preslikavanja $h_i(x)$ u $h_0(y)$ koristeći funkciju izvodnicu za preslikavanje histograma

$$h_0(y) = h_i(f^{-1}(y)) \frac{d(f^{-1}(y))}{dy} \quad (1)$$

koju primjenimo na funkciju linearnog poboljšanja kontrasta

$$y = f(x) = ax + b \quad (2)$$

dobivamo modificirani histogram

$$h_0(y) = \frac{1}{a} h_i\left(\frac{y-b}{a}\right) \quad (3)$$

budući da je:

$$x = f^{-1}(y) = \frac{y-b}{a} \Rightarrow \frac{d(f^{-1}(y))}{dy} = \frac{1}{a} \quad (4)$$

Preostaje još samo odrediti koeficijente a i b koji se mijenjaju od snimke do snimke. Njih određujemo iz samog histograma satelitske snimke

u promatranom kanalu. Na primjer, u histogramu toplinskog infracrvenog područja jasno se vidi nekoliko vrhova od kojih oni s najmanjom vrijednosti (apscisa), predstavljaju tople dijelove snimke koji sadrže radijancu s tla i površine mora. Uzeli smo u obzir invertiranje slike u toplinskom kanalu u kojem hladniji dijelovi snimke imaju veće vrijednosti piksela. Na slici 3 vidimo izgled izvornog histograma u toplinskom spektru, linearne funkcije preslikavanja koja je postavljena tako da segmentira piksele s vrijednostima većim od 40 preko izraza (3) povećavajući pri tome kontrast rezultirajuće snimke. Zbog povećanja kontrasta linearno preslikavanje ima prednost u odnosu na obično maskiranje piksela s vrijednostima manjim od granične vrijednosti. Funkcije za linearno preslikavanje histograma u našem slučaju bile su

$$y = 1.308x - 78.462, \text{ za vidljivi do bliski infracrveni kanal, granična vrijednost bila je } 60$$

$$y = 1.186x - 47.430, \text{ za infracrveni toplinski kanal}$$

Rezultat su segmentirane snimke na kojima su ostali samo oblaci što je vidljivo usporedbom slika 1 i 2 sa slikama 4 i 5.

Segmentacijom pripremljen kompozit od dva kanala staviti ćemo na ulaz iteracijskog algoritma ISODATA zadajući parametre: maksimalnog broja klasa 6, konvergencije kod 0.999 dijelova uzorka ne mijenja klasu tijekom zadnje iteracije i maksimalan broj iteracija od 32. U nekoliko pokušaja varirali smo broj klasa i broj iteracija dok nismo došli do tog optimuma. Prevelik broj iteracija dovodi do *preučenosti* (engl. *overtraining*) i degradacije klasifikacijskog postupka, a prevelik broj klasa dovodi do razdvajanja jednog roda oblaka u nekoliko klasa ovisno o razlikama u iradijanci te zenitnim kutevima. Algoritam ISODATA nećemo na ovom mjestu detaljno opisivati budući da o njemu postoji obilje raspoložive literature (Schrader, Pouncey, 1997). Reći ćemo samo da on pretpostavlja broj klasa tijekom inicijalizacije i u iteracijama provjerava jesu li zadovoljeni kriteriji za razdvajanje ili ujedinjenje tih klasa. Postupak se nastavlja dok se ne iscrpi dozvoljeni broj iteracija ili dok broj pik-

sela koji su tijekom zadnje iteracije promijenili klasu ne postane manji od zadane granične vrijednosti. Za određivanje kriterija razdvajanja ili ujedinjenja koriste se euklidske udaljenosti srednjeg vektora klastera i vektor standardnog odstupanja. Rezultat je automatski klasificirana slika na kojoj su istaknuti klasteri koji predstavljaju rodove oblaka. Nužan je završni korak interpretacije u kojem se tim klasama pridružuju odgovarajući rodovi oblaka na temelju iskustva ili pomoću dopunskog analitičkog materijala s podacima iz meteoroloških postaja.

Slika 6 ima očitu prednost nad nesegmentiranom slikom na kojoj bi se pojavile klase i iznad vrednih područja zbog radijance s kopnene i morske površine. Klasifikator je pokazao dobro slaganje sa sinoptičkom kartom za taj dan. Primijetimo da su tijekom segmentacije ostali sačuvani čak i tanki cirostratusi, zbog njihovih karakterističnih visokih vrijednosti piksela. Na tom primjeru vidi se kako klasifikatori bez nadzora, zbog jednostavnosti i brzine, imaju perspektivu u automatskoj obradi satelitskih snimki. Segmentacija omogućava zadržavanje samo objekata od interesa i time znatno olakšava interpretaciju.

3. SEGMENTACIJA NAKON KLASIFIKACIJE POD NADZOROM

Segmentacija nije ograničena samo na pripremu fazu prije klasifikacije. U slijedećem primjeru koristili smo peterokanalne snimke satelita NOAA Polar Orbiter sa senzorom AVHRR. Izabrana je situacija prolaska hladne fronte koja je upravo 14. siječnja 1998. počela zahvaćati naše krajeve. Korištena je popodneva satelitska snimka napravljena u vremenu od 13:41:54 do 13:53:06 UTC.

Izvorna snimka nema anotaciju tako da smo naknadno unijeli nazive mora radi lakšeg snalaženja. Izabrali smo drugi, prvi i peti kanal za stvaranje kompozita jer senzor AVHRR (kao ni većina satelitskih senzora) ne prima zračenje u plavom dijelu vidljivog spektra, na koje ima jak


utjecaj Rayleighovo raspršenje. Umjesto plavog područja postavili smo toplinsko infracrveno područje od 11.5-12.5 μm , zbog toga visoki i hladni oblaci imaju na slici 7 plavi ton.

Riječ je o vrlo kvalitetnom satelitskom materijalu, za čiju smo obradu koristili metodu Mahalanobisove klasifikacije. Mahalanobisov klasifikator radi pod nadzorom, što znači da prethodno moramo pripremiti uzorke za učenje sa slike. Uzorci su prikupljeni na temelju motrenih podataka koji su potom ucrtani na analitičke karte u izdanju Deutscher Wetterdeinsta. Na žalost, na tim kartama bilo je premalo uzoraka za naknadnu ocjenu točnosti klasifikatora.

Na slici 8 prikazano je ukupno 15 uzoraka na temelju kojih je provedena klasifikacija: jedan uzorak za kumulonimbus, dva za altokumululus, tri za altostratus, dva za stratokumululus, tri za ciruse i četiri za stratus. Nakon klasifikacije pikseli slike bit će pridruženi nekoj od tih pet klasa. Klasifikacija oblaka izvediva je zahvaljujući karakterističnim razlikama u spektralnim radijancama oblaka u različitim dijelovima spektra. Kao ilustraciju te činjenice prilažemo skaterogram u multispektralnom prostoru značajki između kanala 2 i 4 koji su u slaboj korelaciji, tako da su klase jasno razdvojive.

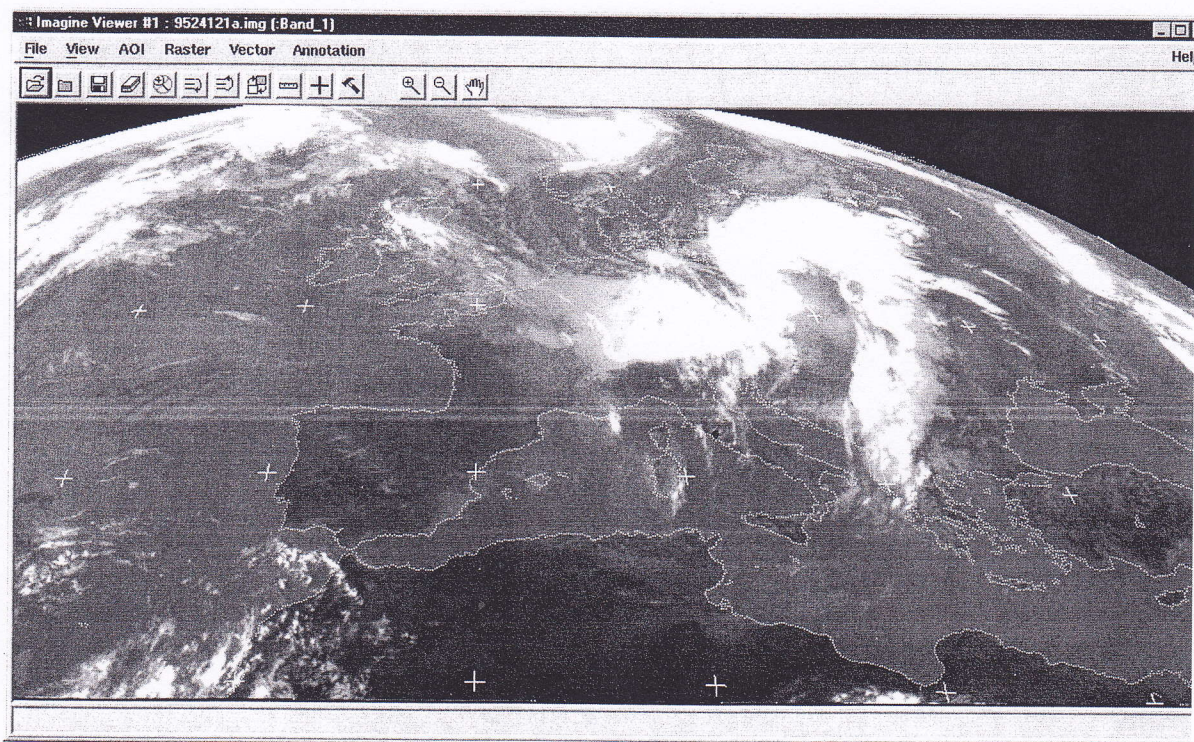
Slika 9 prikazuje frekvenciju pojavljivanja piksela određenih vrijednosti (0-1023) u drugom i četvrtom kanalu. Veća učestalost prikazana je toplijim bojama spektra. Vidimo da se stratusi drže nekoliko klastera s niskim vrijednostima u oba kanala, stratokumululusi su jako raspršeni u multispektralnom prostoru značajki, cirusi imaju, zbog ledene strukture, vrlo nisku radijancu u drugom kanalu (blisko infracrveno područje) i veliku u četvrtom kanalu (Lipovšćak, 1986). Na skaterogramu su prikazani položaji srednjeg vektora i elipse koja predstavlja granicu tri standardne devijacije za svaki uzorak. Multispektralni prostor značajki za AVHRR-snimke ima pet dimenzija, tako da ga nije moguće prikazati.

Klasifikatori koji se koriste u daljinskim istraživanjima koriste razlike u statističkim parametrima tih klastera kako bi ispitivani piksel pri-



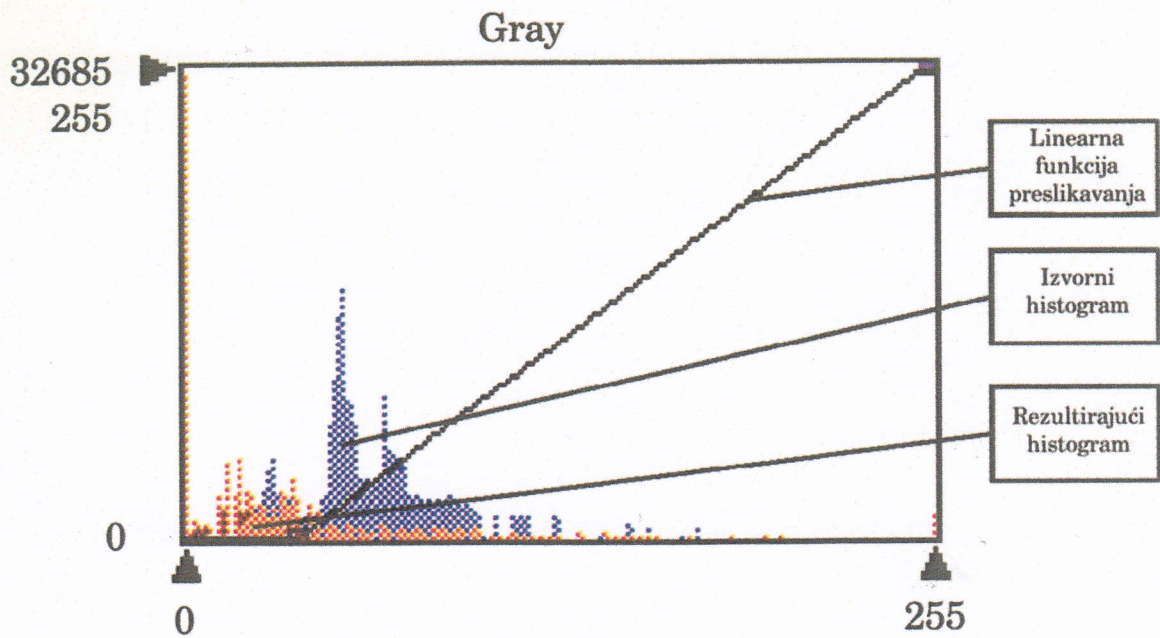
Slika 1. Satelitska snimka Meteosata 5 u vidljivom do bliskom infračrvenom dijelu spektra. 24. prosinca 1995. 1200 UTC

Figure 1 Meteosat 5 satellite image in visible to near infrared part of spectrum. 24. December 1995, 1200 UTC




Slika 2. Drugi dio satelitskog kompozita, snimka u toplinskom infračrvenom dijelu spektra. 24. prosinca 1995. 1200 UTC

Figure 2 The second part of satellite composite, image in thermal infrared part of spectrum. 24 December 1995, 1200 UTC




Slika 3. Histogram kanala u toplinskom infracrvenom dijelu spektra. Odnosi se na sliku 2

Figure 3 Thermal infrared channel histogram. Related to Fig. 2



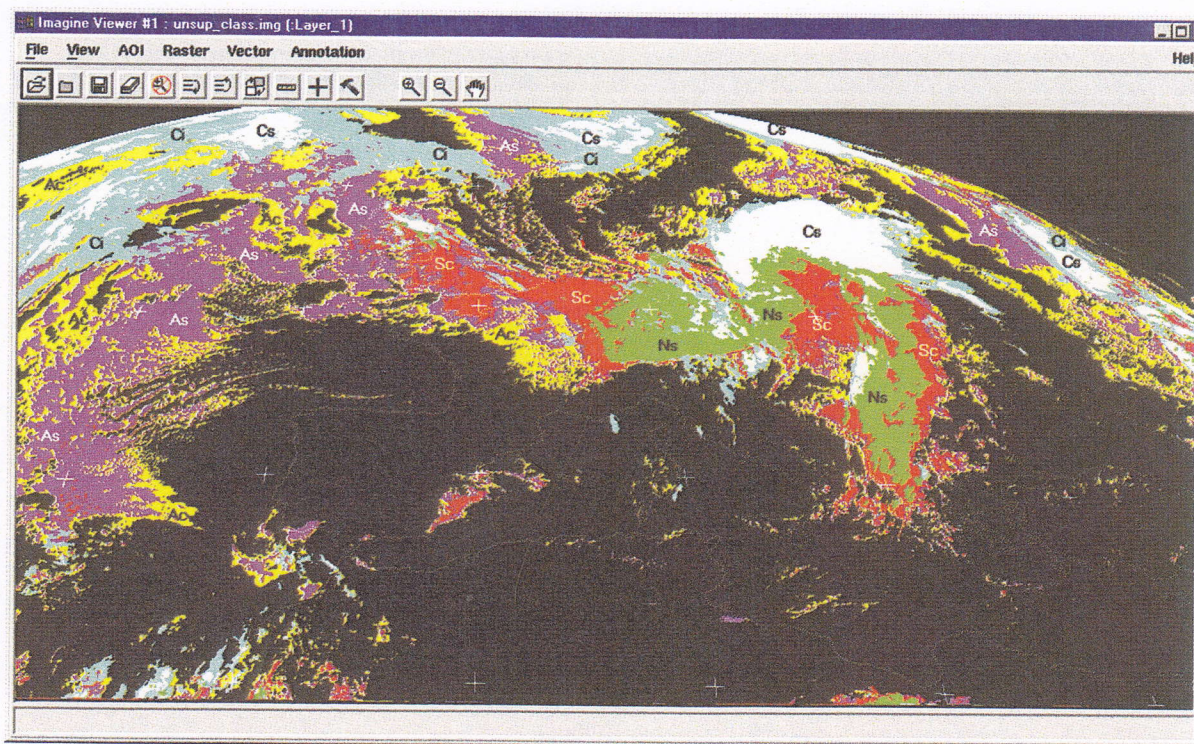
Slika 4. Oblaci segmentirani sa satelitske snimke u vidljivom do bliskom infracrvenom dijelu spektra (Usporedi sa slikom 1)

Figure 4 Clouds segmented on satellite image in visible to near infrared part of spectrum (Compare with Fig. 1)



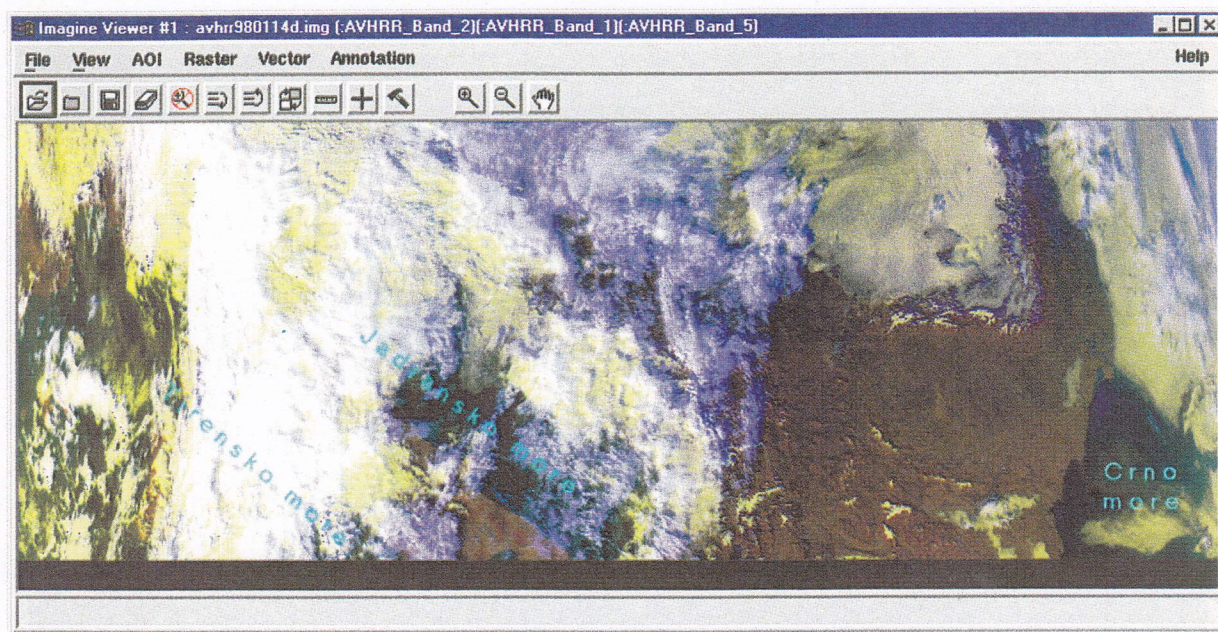
Slika 5. Oblaci segmentirani na satelitskoj snimci u toplinskom infracrvenom dijelu spektra. Usporedi sa slikom 2)

Figure 5 Clouds segmented on satellite image in thermal infrared part of spectrum. (Compare with Fig. 2)



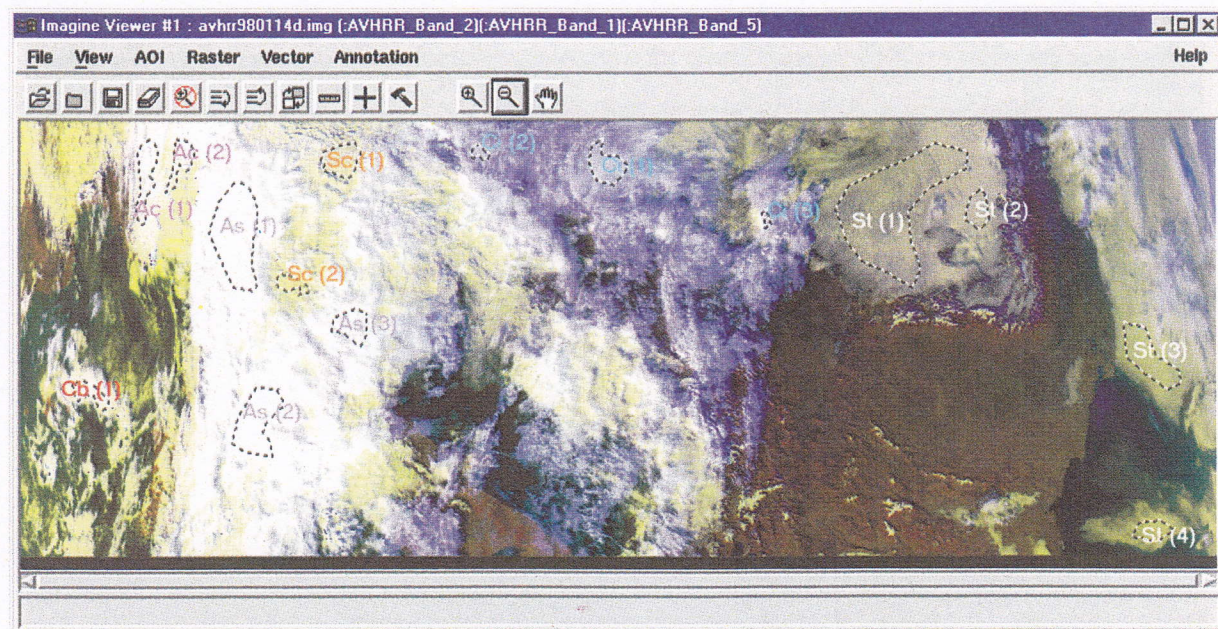
Slika 6. Snimka satelita Meteosat 5 klasificirana klasteringom ISODATA koji prepoznaje 6 klasa (rodova oblaka)

Figure 6 Meteosat 5 satellite image classified by ISODATA clustering which recognises 6 classes (types of clouds)



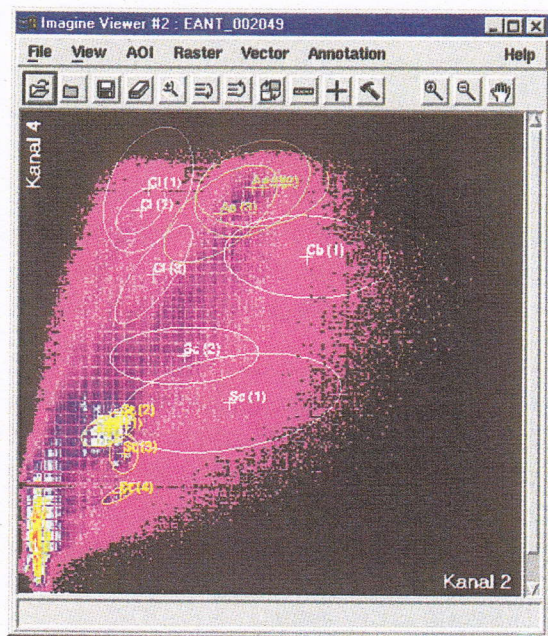
Slika 7. Izvorna snimka NOAA AVHRR. Kompozit je sastavljen od tri kanala po ključu RGB=215

Figure 7 The original NOAA AVHRR image. Composite of three channels according to key RGB=215



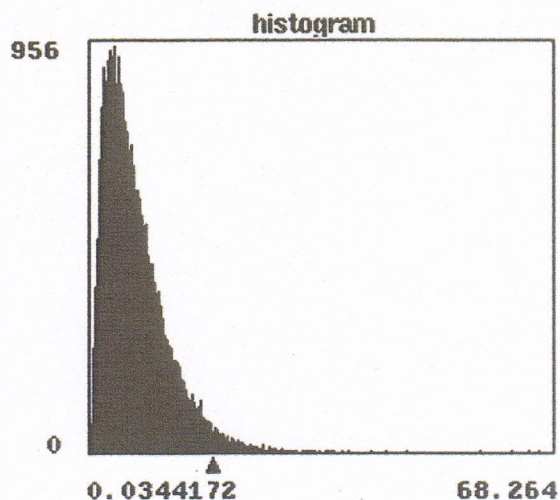
Slika 8. Uzorci za učenje izdvojeni s izvorne AVHRR satelitske slike

Figure 8 Training samples picked up from the original AVHRR image




Slika 9. Skaterogram između kanala 2 i 4 ima slabu korelaciju tako da je na njemu jasno vidljiv položaj klasa u multispektralnom prostoru značajki

Figure 9 Scattergram between channels 2 and 4 has weak correlation so position of classes in multispectral space is quite evident



Slika 10. χ^2 -razlika Mahalanobisovih udaljenosti u slučaju uzorka altokumulusa

Figure 10 χ^2 -distribution of Mahalanobis distances for one altocumulus sample



Slika 11. Snimka NOAA AVHRR klasificirana Mahalanobisovim klasifikatorom i segmentirana pomoću χ^2 -razdiobe Mahalanobisovih udaljenosti

Figure 11 Mahalanobis classification of NOAA AVHRR image and segmentation by χ^2 -distribution of the Mahalanobis distance

Tablica 2. Osnovni statistički parametri za jedan od uzoraka stratusa

Table 2 Basic statistical parameters for one of stratus samples

Signature file: /nusr8/home/mladen/martina-scc/avhrr980114d.sig
 Source image file: /nusr8/home/mladen/martina-scc/avhrr980114d.img
 Number of signatures: 15
 Number of layers: 5
 Signature: St (1)
 Number of pixels: 16939

Statistics				
Layer	Minimum	Maximum	Mean	Sigma
1	103.000	168.000	139.449	8.867
2	95.000	153.000	125.515	8.039
3	736.000	835.000	775.438	11.484
4	545.000	576.000	564.307	5.590
5	526.000	550.000	539.416	5.007

Covariance					
Layer	1	2	3	4	5
1	78.628	270.546	41.958	24.927	17.088
2	270.546	64.620	31.039	26.046	19.006
3	41.958	31.039	131.879	3.561	-3.150
4	24.927	26.046	3.561	31.243	27.360
5	17.088	19.006	-3.150	27.360	25.072

družili klasi kojoj najvjerojatnije pripadaju. Udaljenost od srednjeg vektora u (peterodimenzionalnom) multispektralnom prostoru značajki jest logični parametar. Kod klasifikacije oblaka nije dovoljan budući da su klasteri raspršeni nejednoliko po smjerovima u multispektralnom prostoru značajki. Zbog toga koristimo Mahalanobisov klasifikator, koji uzima u obzir matricu kovarijanci, odnosno preferiranog smjera raspršenja. Za svaki uzorak izračunat je srednjak i matrica kovarijanci, kao što je to prikazano u tablici 2 za prvi uzorak stratusa:

Mahalanobisova udaljenost definirana je kao

$$D_M = [X - M_C]^T \cdot Cov_C^{-1} \cdot [X - M_C] \quad (5)$$

gdje su

- D_M — Mahalanobisova udaljenost
- X — položajni vektor promatranog piksela u multispektralnom prostoru
- M_C — srednji vektor ispitivane klase

Cov_C^{-1} — inverzna matrica kovarijance za ispitivanu klasu C

Preko matrice kovarijanci Mahalanobisova udaljenost preferira smjerove u kojima se raspršuju pikseli u uzorku za učenje. Propuštanjem snimke kroz Mahalanobisov klasifikator svi pikseli pridruženi su jednoj od klasa iz uzoraka za učenje prema kriteriju najmanje Mahalanobisove udaljenosti. To nije realna situacija jer će se kao klasificirani naći i pikseli slike na kojima uopće nema oblaka. Zbog toga, nakon klasifikacije, izvodimo segmentaciju.

Kriterij segmentacije bit će granična Mahalanobisova udaljenost. Graničnu Mahalanobisovu udaljenost za pojedine uzorke za učenje odredit ćemo iz njihove razdiobe koja približno odgovara χ^2 -razdiobi. To nije potpuno točno budući da komponente vektora nisu nezavisne varijable (vidi matricu kovarijanci u tablici 2), ali je u praksi dobra aproksimacija. Na primjeru jednog od uzoraka altokumulusa prikazan je izbor granične vrijednosti iza koje pikseli ostaju neklasi-

ficirani (klasi se pridružuju samo pikseli koji ostaju lijevo od granične vrijednosti u razdoblju).

Postavljanjem strožih kriterija segmentacije sve više piksela ostaje neklasificirano, ali je manja vjerojatnost da se klasi pridruže pikseli koji joj uopće ne pripadaju. Ne postoji objektivna mjera koliko strogi trebaju biti segmentacijski kriteriji, tako da se o tome procjena može dati samo na temelju iskustva.

Na slici 11 prikazan je rezultat Mahalanobisove klasifikacije pomoću 15 uzoraka za učenje i segmentacije postavljanjem granične vrijednosti u χ^2 -razdiobi Mahalanobisovih udaljenosti za svaki od uzoraka. Postupak je mnogo zahtjevniji od ranije prikazanog visokoautomatiziranog algoritma ISODATA. Usporedba sa sinoptičkom kartom napravljenom u 12 sati istog dana pokazuje dobro slaganje uz dvije primijećene pogreške pri klasifikaciji: snijeg na balkanskim planinama klasificiran je kao stratokumululus te nisu klasificirani stratusi na krajnjem istoku snimke zbog bitno različite radijance izazvane nepovoljnim zenitnim kutem Sunca. Relativno mala površina klasificirana kao stratokumululus posljedica je velike radiometrijske raznolikosti tih oblaka, na kojima su česta područja s vlastitom sjenom ili sa sjenom viših oblaka. Sjena izaziva radiometrijske poremećaje zbog kojih su stratokumulusi jako raspršeni u multispektralnom prostoru značajki, kao što to prikazuje skaterogram na slici 9. Konačno, stratokumulusi su često zaklonjeni slojem viših oblaka.

4. ZAKLJUČAK

Na temelju dva primjera napravljena na suvremenim satelitskim sensorima pokazana je prak-

tična primjena klasifikacije oblaka na dva konceptijski potpuno različita klasifikacijska postupka. Nužnost automatske klasifikacije satelitskih snimki u meteorologiji doći će do još većeg izražaja u obradi hiperspektralnih snimki kakve će uskoro početi pristizati u okviru međunarodnog projekta *Earth Science* (donedavno pod nazivom *Mission to Planet Earth*) i u operativni uvođenjem novih satelitskih senzora, kao što je MSG (Meteosat Second Generation, koji će imati 12 kanala). Postupci klasifikacije, razvijeni u digitalnoj obradi slike za potrebe daljinskih istraživanja, moraju se prilagoditi meteorološkim potrebama. Jedna od takvih prilagodbi jest uvođenje segmentacije prije klasifikacije ili poslije nje. Problem segmentacije nije došao do izražaja u prijašnjim aplikacijama za daljinska istraživanja jer se na njima redovito koriste satelitske snimke bez oblaka, a područja koja su snimljena imaju malu površinu na kojima su gotovo svi objekti od primarnog interesa.

5. LITERATURA

- Bankert R.L., Aha D.W., 1996: Automated Identification of Cloud Patterns in Satellite Imagery, Naval Research Laboratory, interno izvješće, 4 stranice
- Kidwell K.B., 1995: NOAA Polar Orbiter Data Users Guide, NOAA, Washington D.C.
- Lipovšćak B., 1986: Identifikacija oblačnih sustava na temelju numeričkih satelitskih podataka, Disertacija, Sveučilište u Zagrebu
- Schrader S., Pouncey R., 1997: ERDAS Field Guide 4th Edition, ERDAS Inc., Atlanta GA
- Viher M., 1995: Digitalna obrada radarskih snimki intenziteta oborine, stručni rad, Državni hidrometeorološki zavod, Zagreb