

AUTOMATSKA KLASIFIKACIJA SATELITSKIH SLIKA OBLAČNIH SUSTAVA

Dr. Bojan LIPOVŠČAK
Republički hidrometeorološki
zavod, Zagreb

UDK 528.8 551.576
551.509 324. 1.001.33
551.507. 362.2
Izvorni znanstveni rad
Prispjelo: 6. 02. 1989
Prihvaćeno: 28. 02. 1989.

1. UVOD

Proučavanje vremenskih procesa radi izdavanja prognoze ili upozorenja o nailasku opasnih vremenskih pojava uvjetuje neprekidno prikupljanje meteoroloških podataka s velikih područja Zemlje. Raspored meteoroloških stanica i osmatračkih točaka uvjetovan je naseljenošću, oblikom terena, pristupačnošću pojedinoj lokaciji te je vrlo nejednoliko raspoređen na kopnu, dok je s morskih prostranstava moguće dobiti podatak samo s brodova ili meteoroloških plutača. Oblačni sistemi, rod i vrsta naoblake, oduvijek su bili predmet intenzivnih proučavanja zbog njihove povezanosti s karakterom vremena koje svojim prisustvom donose. Upotrebom radara sredinom dvadesetog stoljeća ostvarena je mogućnost praćenja oborinskih zona i određivanja količine oborine u dometu radarskih mjerenja nad područjima s kojih do tada takvih podataka nije bilo. Upotrebom satelita u meteorologiji početkom šezdesetih godina ostvarena je mogućnost dobivanja slika oblačnih sistema iz svemira i neprekidnog praćenja razvoja oblaka na planetarnoj skali.

Pojavom prvih satelitskih slika oblačnih sistema razvijaju se i prvi pokušaji raspoznavanja tipova oblaka i njihova klasifikacija. Prve klasifikacije temelje se na upotrebi analognih satelitskih slika u vidljivom dijelu Spektra. (Conover, 1962; Kondratjev, 1966; Anderson, 1966; Lee i Taggart, 1969), a raspoznavanje različitih vrsta oblaka vrši se na osnovi oblika, tkiva oblačne mase i svjetline.

Upotrebom analognih slika infracrvenog dijela spektra razvijene su metode koje klasifikaciju temelje na temperaturi vrha oblaka i tkivu oblačne mase. Rao (1970) pokazuje da se na osnovi histograma infracrvene slike oblaka može doći do podatka o tipu i količini naoblake.

Informacija u dva valna područja — vidljivom i infracrvenom — navodi na razvijanje metoda koje koriste oba kanala za klasifikaciju oblaka. Osnovni ulazni podaci za klasifikaciju su: temperatura vrha oblaka, svjetlina, tkivo i oblik. Barends i Chang (1968) ustanovljavaju da je moguće na osnovi mjerenja u više spektralnih područja ostvariti klasifikaciju oblaka, a Anderson (1969) prikazuje metodu klasifikacije oblaka baziranu na analizi analognih podataka u vidljivom i infracrvenom dijelu spektra. Harris i Barret (1975) diskutiraju postjeće metode analize satelitskih slika oblačnih sistema (neph analize) i predlažu novu metodologiju kojom je analitičaru omogućen brži rad na analizi naoblake, a sadržaj informacija analizirane slike povećan je za 3 do 5 puta.

Greaves i Chang (1970) upotrebljavaju statističku metodu i raspoznaju pet osnovnih kategorija oblaka upotrebom digitalnih podataka 3 valna područja 0.2–0.4, 6.4–6.9, i 10.0–11.0 μm . Lo i Johnson (1971) upotrebljavaju bivarijantnu distribuciju frekvencija za izdvajanje različitih osobina oblaka na osnovi podataka satelita NIMBUS-2 u valnim područjima 6.4–6.9 μm , i 10.0–11.0 μm . Both (1973) kombinira multispektralni pristup u 2 valne duljine 0.5–0.7 i 10.5–12.5 μm s metodom ekstrakcije svojstava (feature extraction) i klasificira oblake u 8 klasa. Bizari (1976) pretpostavlja da su tipovi oblaka povezani sa specifičnom spektralnom strukturom na dvodimenzionalnom histogramu čestina. Metoda automatskog odjeljivanja i svrstavanje oblaka u razrede Senek-a (1976) temelji se na pragovima vrijednosti temperature dobivene iz satelitskih mjerenja, koja definira matricu odluke za svrstavanje oblaka u razrede. Senek upotrebljava podatke 4 kanalnog skenera valnih duljina 0.2–0.4, 6.5–7.0, 10.0–11.0 i 20.0–23.0 μm . Za klasifikaciju su potrebni i podaci vertikalnog profila temperature i vlažnosti zraka, te klimatološki podaci visine vrhova oblaka. Reynolds i suradnici (1977) razvijaju dvospektralnu metodu za određivanje količine naoblake upotrebom vidljivih i infracrvenih satelitskih slika. Szevach i suradnici (1978) razvijaju shemu za dinamičku klasifikaciju oblaka mezo skale, temeljenu na razlici uzastopnih slika naoblake nad istim područjem dobivenih s geostacionarnog satelita. Reynolds i suradnici (1978) razvijaju metodu za detekciju i separaciju oblaka iz satelitskih mjerenja infracrvenog dijela spektra. Parikh i Rosenfeld (1978) razvijaju algoritam za klasifikaciju oblaka na temelju podataka infracrvenog dijela spektra. Algoritam povezuje statističku metodu grupiranja u klase (clustering) i tehnike segmentacije slike. Cayla (1978) ukazuje na problem klasifikacije transparentnih cirusa i predlaže upotrebu kanala valne duljine 5.7–7.1 μm , meteorološkog satelita METEOSATA u kojem je jaka apsorpcija vodene pare. Parikh i Ball (1980) klasificiraju infracrvene podatke mjerenja satelita SMS1 u 5 razreda na osnovi temperature i Robertsovog gradijenta. Smith (1981) predlaže arhiviranje meteoroloških satelitskih podataka u obliku histograma, osnovni je cilj zadržavanje informacije o radijacionim svojstvima oblaka. Liljas (1981, 1984) razvija shemu klasifikacije visoko rezolutnih podataka satelita NOAA 7 u tri spektralna područja metodom fiksnih granica vrijednosti među klasama. Desbois i suradnici (1982) razvijaju metodu za klasifikaciju oblaka primjenom clusteringa, tj. grupiranja podataka tri valne duljine geostacionarnog satelita METEOSAT. Simmer i suradnici (1982) pokazuju da su digitalni podaci satelita u vidljivom i infracrvenom dijelu spektra raspoređeni po zakonu normalne ili Gaussove razdiobe. U radu WMO

(1984) dan je prikaz — uspoređenje algoritama za analizu oblaka na osnovi satelitskih mjerenja. Osnovni je cilj dobivanje klimatoloških podataka o radijaciji Zemlje i utjecaju oblaka na radijacionu bilancu Zemlje. Lipovščak (1983, 1983 a, 1984 1986) razmatra primjenu višedimenzionalne normalne funkcije gustoće vjerojatnosti za dizajniranje klasifikatora oblaka koji primjenjuje na podacima visoko rezolutnog skenera satelita serije NOAA 6 i 7. Paket programa zasnovan na predloženoj metodologiji, te organizacija i rad s bazom podataka, prikazani su u radu Mehtrea i suradnika (1985, 1986). Lipovščak (1987) prikazuje rezultate primjene postupka automatske klasifikacije oblaka na klasifikaciju podloge (tla) i klasificira četiri različite klase na temelju podataka satelita LANDSAT.

1.2. FIZIKALNE OSNOVE DALJINSKOG MJERENJA I KLASIFIKACIJE OBLAKA

Daljinska istraživanja (remote sensing) pomoću meteoroloških satelita temelje se na mjerenju radijacije sistema Zemlja — atmosfera pomoću višekanalnih spektrometara.

Princip mjerenja satelitskim skenerom svodi se na mjerenje temperature, što slijedi iz Planckovog zakona radijacije. On povezuje gustoću energije radijacije, valnu duljinu zračenja i temperaturu tijela u obliku:

$$M_\lambda = \varepsilon C_{1/\lambda^5} (\exp(C_2/\lambda T) - 1)^{-1}, \quad (1)$$

gdje su:

- M_λ — spektralna gustoća energije zračenja u dijelu spektra oko valne duljine λ u ($W m \mu m$).
- ε — konstanta emisivnosti
- C_1 — $3.7413 \cdot 10^8 W m^2 \mu m^2$ prva konstanta zračenja
- λ — valna duljina radijacije μm
- C_2 — $1.4388 \cdot 10^4 \mu m K$, druga konstanta zračenja
- T — termodinamička temperatura tijela

ε je konstanta koja poprima vrijednosti:

- 0 za savršeni reflektor,
- 1 za savršeno crno tijelo,
- $0 < \varepsilon < 1$ za sivo tijelo,
- $\varepsilon = f(\lambda)$ za sve ostalo.

Satelitski senzor prima zračenje sa Zemlje. Snaga zračenja proporcionalna je spektralnom zračenju cilja, otvoru senzora, vidnom polju senzora, valnoj duljini elektromagnetskog spektra i prozirnosti atmosfere za zračenje. Matematički se snaga reflektiranog zračenja koju senzor prima može prikazati kao:

$$L_\lambda = 1/\pi R E_\lambda \cos \theta_s, \quad (2)$$

gdje je:

- E_λ — spektralna iradijanca — snaga zračenja po jedinici površine cilja,
- R — dvosmjerni faktor refleksije,
- θ_s — kut Sunca.

Za termički dio spektra spektralna je radijacija cilja definirana kao:

$$L_\lambda = 1/\pi E_\lambda \cos \theta_s. \quad (3)$$

Spektralna iradijanca definirana je Planckovim zakonom radijacije (1). Upadna snaga zračenja je, prema tome, funkcija temperature cilja. Temperatura cilja se u vidljivom dijelu spektra (reflektivni dio spektra) naziva i temperatura boje.

Za daljinsko mjerenje satelitom oblaci predstavljaju cilj koji zračenje Sunca reflektira u vidljivom dijelu

spektra, a zrači energiju u infracrvenom dijelu spektra. Temperatura oblaka funkcija je visine na kojoj se oblak nalazi. Visina oblaka definira tip oblaka. Temperatura boje oblaka ovisi o gustoći oblačnih čestica, njihovom sastavu (led ili voda) i veličini, dakle veličinama koje definiraju različite tipove oblaka. Možemo zaključiti da se satelitskim skenerima mjere fizička svojstva oblaka koja omogućuju konstrukciju klasifikatora tipova oblaka.

2. RASPOZNAVANJE OBLAKA NA OSNOVI DIGITALNIH SATELITSKIH PODATAKA — PRIMIJENJENA METODOLOGIJA

Polarno orbitalni sateliti operativno pokrivaju Zemlju s digitalnim podacima osmatranja satelitskih skenera rezolucije od 250 m do 30 km, (Lipovščak, 1985 b), a nad istim dijelom Zemlje nalaze se svaka tri sata. Geostacionarni sateliti dostavljaju svakih 30 minuta podatke u digitalnom obliku za cijeli Zemljin disk. Ogromna količina informacija, koje se na taj način prikupljaju, postala je otežavajuća činjenica u analizi satelitskih slika. Procjenjuje se da je za arhiviranje svih sirovih satelitskih podataka (digitalnih slika) godišnje potrebno 200.000 magnetskih traka gustoća zapisa 1.600 bpi.

Zahtjevi postavljeni automatskom klasifikatoru jesu:

1. raspoznavanje se mora vršiti na osnovi radijacijskih svojstava oblaka;
2. raspoznavanje mora biti moguće vršiti za vrijeme noćnih i dnevnih preleta satelita (noću su odsutni podaci u vidljivom dijelu zračenja);
3. raspoznavanje mora biti primjenjivo u svim geografskim širinama;
4. klasifikator mora biti modularan, tako da je moguće u proces identifikacije unijeti dodatne postupke određivanja klasa (pragovi, a priori vjerojatnost, tkivo i oblik rubova oblaka).

Osim raspoznavanja i svrstavanja oblaka u tipove klasifikator mora biti sposoban raspoznati i svrstati u klase podloge na Zemlji: tlo, vodu (oceani, jezera i rijeke), snijeg i led. S obzirom na svojstva oblaka (temperaturna područja u kojima se javlja i svjetlina), Lipovščak (1983) predlaže raspoznavanje oblaka i vrsta podloge u 11 klasa (Tablica 1.).

Tablica 1.

Klase oblaka i Zemljine površine za koje je učen automatski klasifikator oblaka. Tablica boja pridijeljenih klasama oblaka i pojava.

Klasa	Pojava	Boja
1	Cb	crvena
2	Cucong	svijetlo ljubičasta
3	Ns	siva
4	Ac	tamno smeđa
5	As	tamno ljubičasta
6	Ci, Cs, Cc	svijetlo plava
7	Sc, Cu	žuta
8	St, magla	svijetlo smeđa
9	snijeg	bijela
10	tlo	zelena
11	more, voda	plava
12	nepoznato	crna

Rezultati satelitskih mjerenja pojedinih rodova i vrsta oblaka u nekom području valnih duljina spektra

mogu se prikazati normalnom razdiobom (Simmer i suradnici, 1982; Coakley i suradnici 1984), što navodi na misao da se normalna razdioba primijeni kao funkcija diskriminacije za razlikovanje pojedinih rodova oblaka međusobno, kao i za razlučivanje što je Zemljina površina, a što su oblaci.

Skup mjerenja koja definiraju neki oblak jesu veličine izmjerene satelitskim skenerom visoke moći razlučivanja (AVHRR podaci) u tri valna područja spektra zračenja. Shema modela klasifikatora oblaka prikazana je slikom 1.

X_1
OBLAK → SENZOR → X_2 → KLASIFIKATOR → REZULTAT
 X_3

Slika 1. Model klasifikatora oblaka.

Senzor je satelitski skener, a X_i su vrijednosti izmjerene u različitim valnim duljinama spektra za isti element oblaka (pixel). Za različite vrste oblaka različite su vrijednosti X_i zbog njihovih različitih fizikalnih svojstava.

Lipovščak (1984) diskutira primjenu trodimenzionalne normalne razdiobe kao funkcije diskriminacije među klasama oblaka uz primjenu podataka mjerenja u vidljivom blizu infracrvenom i infracrvenom dijelu spektra. Za 11 klasa pojava za isti kanal mjerenja definira se 11 različitih normalnih razdioba koje su definirane srednjakom i standardnom devijacijom.

U slučaju trodimenzionalne normalne razdiobe potrebno je za svaku funkciju diskriminacije odrediti 9 elemenata: 3 srednjaka i 6 elemenata matrice kovarijanci. Za 11 klasa potrebno je odrediti 99 vrijednosti, i time je definirano 11 različitih trodimenzionalnih normalnih razdioba.

Vjerojatnost da je X iz klase ω_i za višedimenzionalnu normalnu razdiobu, može se napisati u obliku:

$$p(X/\omega_i) = \frac{1}{(2\pi)^{n/2} |\Sigma_i|^{n/2}} \exp(-1/2 (X - \mu_i)' \Sigma_i^{-1} (X - \mu_i)) \quad (4)$$

Za klasifikaciju oblaka na osnovi digitalnih podataka satelitskog skenera velike moći razlučivanja primijenjen je klasifikator tipa maksimalne vjerojatnosti (maximum likelihood). Princip klasifikacije definiran je na slijedeći način:

Neka su $x_1 \dots x_m$ slučajne varijable, gdje je x_j mjerenje i -tog uzorka. Za svaku klasu uzoraka ω_j , $j = 1 \dots m$ pretpostavimo da je poznata multivarijanta (n dimenzionalna) funkcija gustoće vjerojatnosti uzorka X dana s $p(X/\omega_j)$, i vjerojatnost pojave uzorka ω_j prikazana s $P(\omega_j)$. Na osnovi a priori informacije $p(X/\omega_j)$ i $P(\omega_j)$, $j = 1 \dots m$, klasifikator je dužan raspoznati uzorak uz minimalnu vjerojatnost pogreške.

Matematički prikazana funkcija diskriminacije za Bayes-ov klasifikator dana je s:

$$G_i(X) = \ln(P(\omega_i) p(X/\omega_i)) \quad (5)$$

za svaki $i = 1 \dots m$.

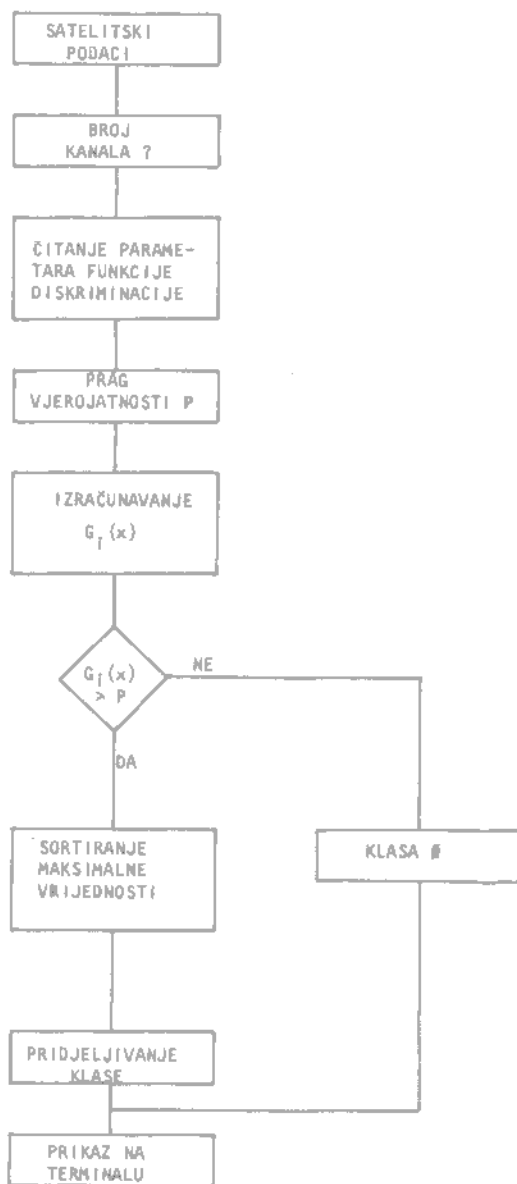
Uz primjenu Bayes-ova pravila (5) funkcija diskriminacije bazirana na višedimenzionalnoj normalnoj razdiobi poprima oblik:

$$G_i(X) = \ln P(\omega_i) - 0.5 \ln |\Sigma_i| - 0.5(X - \mu_i)' \Sigma_i^{-1} (X - \mu_i) \quad (6)$$

Za određivanje a priori vjerojatnosti potreban je duži niz prikupljanja satelitskih podataka i izrada karata čes-

tine pojave pojedinih klasa oblaka, odnosno pojava na nekom području. Za početne korake klasifikacije uzima se da je a priori vjerojatnost pojave određene klase jednaka za sve klase.

Razlikuje se postupak inicijalnog učenja klasifikatora i postupak obnavljanja baze podataka jer su upotrijebljeni različiti algoritmi za izračunavanje vrijednosti parametara funkcije diskriminacije (Lipovščak, 1986).



Slika 2. Shema programskog paketa za učenje klasifikatora i arhiviranje parametara funkcije diskriminacije.

Prameni funkcije diskriminacije među klasama određeni su upotrebom jednadžbi:

$$\mu_{(N+K)} = 1/(N+K) (N\mu_N + K\mu_K) \quad (7)$$

$$\sigma_{(N+K)} = N/(N+K) (\sigma_N + \mu_N \mu_N') + K/(N+K) (\sigma_K + \mu_K \mu_K') - 1/(N+K)^2 (N\mu_N + K\mu_K) (N\mu_N + K\mu_K)' \quad (8)$$

gdje su μ_N, σ_N srednjak i kovarijanca klase i izračunati iz N vrijednosti elemenata slike jednog uzorka, a μ_K, σ_K srednjak i kovarijanca klase i , izračunati iz K vrijednos-

ti elemenata slike drugog uzorka, a $\mu_{(N+K)}$ $\sigma_{(N+K)}$ su srednjak i kovarianca za oba skupa podataka.

Paket programa za izračunavanje parametara funkcije distribucije izrađen je na taj način da omogućava neprekidno nadopunjavanje i izmjenu baze podataka parametara. Osim postupka obnavljanja baze podataka bazu je moguće proširiti uvođenjem novih klasa. Baza podataka parametara može se načiniti za različite vrste satelitskih ili ostalih višespektralnih podataka koji se klasificiraju.

Schema paketa programa za učenje klasifikatora i arhiviranje parametara funkcije diskriminacije prikazana je na slici 2. Prvi je korak programa provjera u bazi podataka satelitskih slika broja raspoloživih kanala za svaki element slike. Korisnik (operater) određuje broj kanala koji će koristiti za izračunavanje parametara funkcije diskriminacije. Nakon otvaranja baze podataka parametara pristupa se izdvajanju uzorka za učenje na ekranu grafičkog računala. Poslije izdvajanja uzorka računalo postavlja pitanje da li se radi o inicijalnom učenju klasifikatora ili o noveliranju baze podataka. Po dobivenom odgovoru koristi se odgovarajući algoritam.

Nakon završetka izračunavanja parametri se upisuju u bazu podataka parametara funkcije diskriminacije među klasama.


U postupak identifikacije, koji je shematski prikazan na slici 3, u jednadžbu kojom je definirana funkcija diskriminacija među klasama moguće je ugraditi granične vrijednosti koje definiraju vjerojatnost da je pojava iz određene klase. Značenje praga je da je vjerojatnost da podatak pripada nekoj klasi zanemarivo mala. Prag vjerojatnosti definira se unaprijed prije postupka identifikacije, i to za svaku klasu posebno ili za sve klase jednakim iznosom. U radu je korišten prag vjerojatnosti 0.05, a algoritam za klasifikaciju zamišljen je tako da sve elemente slike za koje je vrijednost funkcije diskriminacije manja od praga svrstava u klasu nepoznatog porijekla.

```

gi(X)
:
: ODREDI
X → : → NAJVEĆI → REZULTAT
:
: gi(X)
gi(X)

```

Slika 3. Shematski prikaz upotrijebljenog pravila raspoznavanja i svrstavanja u grupe.



Slika 4. Prizemna sinoptička situacija dana 08. 11. 1983. u 00 GMT, nad područjem Indokine i okolnih mora.

Matematički prikazano:

$$g_i(X) < P \text{ nepoznato porijeklo} \quad (9)$$

$$g_i(X) > P \text{ klasifikacija određivanjem maksimalne vrijednosti } g \rightarrow i(X).$$

3. OPIS SLIKA ZA UČENJE KLASIFIKATORA

Za početno učenje klasifikatora izdvojeni su podaci koje je satelit NOAA-7 dostavljao za vrijeme preleta orbitama broj 12522 i 13323. Primljeni podaci sadrže podatke vidljivog (kanal 1), blizu infracrvenog (kanal 3) i infracrvenog (kanal 4) dijela spektra.

Podaci su uneseni u bazu podatka i označeni kao slike 11, 13, 14, 21, 23, 24. Oznake slika odabrane su tako da prvi broj označava redni broj odabrane slike za učenje, a drugi broj označava kanal višespektralnog skenera pomoću kojeg je slika dobivena. Osnovne karakteristike odabranih slika za učenje klasifikatora prikazane su tablicom 2.

Tablica 2.

Karakteristike upotrijebljenih trening slika (Z — Zemlja, M — more, * — snijeg, Mg Magla, rodovi oblaka).

Slika	Orbita	Datum	Kanal	Geografske koordinate	Komentar
11	12522	08. 11. 83.	1.	84E — 110E, 04N — 15N	Cb, Ci, Cs, As, M, Z
13	12522	08. 11. 83.	3.	84E — 110E, 04N — 15N	Cb, Ci, Cs, As, M, Z
14	12522	08. 11. 83.	4.	84E — 110E, 04N — 15N	Cb, Ci, Cs, As, M, Z
21	13323	23. 01. 84.	1.	71E — 77E, 32N — 36N	Cu, Ci, Z, Mg, *
23	13323	23. 01. 84.	3.	71E — 77E, 32N — 36N	Cu, Ci, Z, Mg, *
24	13323	23. 01. 84.	4.	71E — 77E, 32N — 36N	Cu, Ci, Z, Mg, *

Odabrana slika 1 prikazuje podatke preleta satelita nad područjem Indokine, slika 6. Vrijeme preleta satelita je 13.05, lokalno vrijeme. Prizemna sinoptička karta (slika 4) za isti dan u 00 GMT (04.30, lokalno vrijeme) ukazuje na postojanje niskog tlaka nad područjem Bengalskog zaljeva. Na području koje je prikazano ovom slikom zamijećeni su oblaci roda Cumulonimbus, Cumulus congestus, Cirrostratus, Cirrus, Altostratus i Stratocumulus.

Odabrana slika 2 prikazuje podatke preleta satelita preko Himalaje, i to područje Kašmira i masiva Kara Korum (slika 7). Prizemna sinoptička situacija dana 23. 01. 1984. u 0 GMT (slika 5) karakteristična je po vedrom vremenu nad područjem odabrane satelitske slike. Na tlu masiva Himalaje je snježni pokrov, u kotlinama mjestimice ima magle, nad vrhovima planinskog masiva zamijećeni su Strato-cumulusi.

S odabranih slika izdvojena su manja područja koja služe za »učenje« klasifikatora. Područja učenja predstavljena su s 512 × 512 elemenata slike na ekranu grafičkog računala.


3.1. PRVO PODRUČJE UČENJA

Prvo područje učenja prikazano je na slici 6. uz pomoć podataka trećeg kanala skenera, a definirano je geografskim koordinatama 5N i 95E, koje prolaze središtem slike. Slika predstavlja područje Andamanskog mora sa zapadnim rtom otoka Sumatre (središnji donji dio slike). Na području učenja istaknute su slijedeće klase pojava: more, Cumulonimbus, Altostratus, Stratocumulus, Cumulus te Cirrus. Čestinu pojavljivanja pojedinih nijansi sive skale u pojedinom kanalu mjerenja skenera prikazuju histogrami na slici 8. Analiza histograma ukazuje na postojanje maksimuma (slika 8b i 8c) koji odgovara vrijednosti sive skale mora (kanal 3 i kanal 4). Histogram čestine pojavljivanja nijansi sive skale za prvi kanal mjerenja u vidljivom dijelu spektra (slika 8a) ukazuje na najveću čestinu 18.800 za vrijednost sive skale 93 koja odgovara srednjaku klase oblika Stratocumulus i Cumulus. Sekundarni maksimum čestine ima vrijednost 380 za vrijednost sive skale 109, koja odgovara klasi Altostratus.


3.2. DRUGO PODRUČJE UČENJA

Drugo područje učenja klasifikatora predstavlja površinu Zemlje na geografskim koordinatama 9N širine i 99E dužine, predstavlja Malezijski poluotok u predjelu prevlake Kra, s dijelom Andamanskog mora i Tajlandskim zaljevom na istoku. Na tom području istaknute su klase pojava; more, kopno, Altostratus, Stratocumulus, Cumulus, Cirrus, Stratus i Cumulus congestus.


Čestina pojave nivoa sive skale u pojedinom kanalu mjerenja za drugo područje prikazano je histogramom na slici 9. Histogram čestine sive skale za ovo područje učenja u vidljivom dijelu spektra (slika 9a) karakteriziran je maksimumom za vrijednost 87 koja odgovara klasi more, i za vrijednost 114 koja je najbliža klasi Altostratus. Na histogramu čestine sive skale kanala 3, (slika 9b) izražen je maksimum za vrijednost sive skale 14, koja odgovara klasi more, i sekundarni maksimum




Slika 6. Prvo područje učenja klasifikatora s uokvirenim poznatim uzorcima oblaka i podloge prikazano kolor kompozitnom slikom kanala 1, 3 i 4, na temelju podataka satelita NOAA 7, dana 08. 11. 1983, u orbiti br. 12522.




Slika 5. Prizemna sinoptička situacija dana 23. 01. 1984. u 00 GMT, nad područjem sjeverne Indije i masiva Himalaje.




Slika 7. Odabrana slika s uzorcima (zaokruženi dijelovi) za učnije klasifikatora snimljeno iz satelita NOAA 7, dana 23. 01. 1984., u orbiti br. 13323, kolor kompozitna slika.




Sl. 8/a) vidljivi dio spektra, kanal 1;



Sl. 8/b) blizu infracrveni dio spektra, kanal 3;




Sl. 9/b) blizu infracrveni dio spektra, kanal 3;



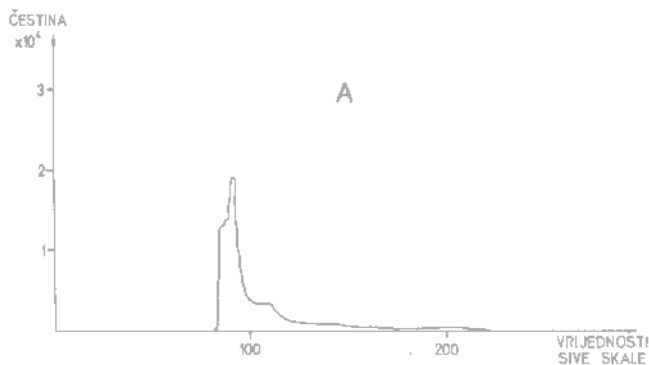
Sl. 8/c) infracrveni dio spektra, kanal 4.

Slika 8. Histogrami čestine pojavljivanja pojedinih nijansi sive skale na prvom odabranom području za učenje klasifikatora.




Sl. 9/c) infracrveni dio spektra, kanal 4.

Slika 9. Histogrami čestine pojavljivanja pojedinih nijansi sive skale na drugom odabranom području za učenje klasifikatora.



Sl. 9/a) vidljivi dio spektra, kanal 1;




Sl. 10/a) vidljivi dio spektra, kanal 1;

za vrijednost 23 koja je blizu vrijednosti srednjaka za klase zemlja ili Stratus. Histogram čestine sive skale kanala 4 u infracrvenom dijelu Spektra (slika 9c) ukazuje na maksimalnu čestinu za vrijednosti 151 i 154 sive skale, koje odgovaraju klasi tlo. Sekundarni je maksimum za vrijednost 182 koja odgovara klasi naoblake Cirrus.


3.3. TREĆE PODRUČJE UČENJA

Treće područje učenje predstavlja područje Kašmira i masiva Kara Korum. Karakteristične su klase pojava na tom području: snijeg, tlo i sloj magle u središnjem dijelu slike (slika 7).

Za histogram čestine pojave nivoa sive skale u vidljivom i infracrvenom dijelu spektra (slika 10 a, c) za treće područje učenja klasifikatora karakteristična su dva maksimuma koji odgovaraju klasama zemlja i snijeg. U trećem kanalu (slika 10b) najslabije je izražena razlika među klasama te se javlja samo jedan maksimum koji ukazuje na slabu separabilnost među klasama tlo i snijeg u tom području temperatura.



Sl. 10/b) blizu infracrveni dio spektra, kanal 3;



Sl. 10/c) infracrveni dio spektra, kanal 4.

Slika 10. Histogrami čestine pojavljivanja pojedinih nijansi sive skale na trećem odabranom području za učenje klasifikatora.

Izračunate vrijednosti parametara funkcije diskriminacije prikazana su tablicom 3. U tablici nedostaju klase Nimbostratus (3) i Altocumulus (4) jer ih klasifikator još ne raspoznaje, s obzirom na to da na odabranim područjima nije bilo uzorka takvih rodova oblaka.

Tablica 3.

Vrijednosti parametara funkcije diskriminacije izračunatih uz pomoć uzoraka prvog, drugog i trećeg područja učenja.

Klasa	Broj elemenata slike	Srednjak	Kovarijance			
1	2493	209.8	69.9	15.2	-18.9	
		108.2	15.2	327.2	-59.6	
		230.3	-18.6	-59.6	35.1	
2	395	176.1	671.3	317.2	432.9	
		83.4	317.2	655.8	71.5	
		218.9	432.9	71.5	603.4	
3	2616	110.2	7.8	7.6	4.0	
		49.5	7.6	67.8	60.6	
		143.4	4.0	60.6	79.9	
6	2381	166.1	621.9	319.0	521.1	
		46.7	319.0	252.7	285.7	
		206.6	521.1	285.7	504.9	
7	2698	107.0	142.3	73.6	73.4	
		52.4	73.6	191.9	63.1	
		148.6	73.4	63.1	243.7	
8	460	95.9	0.9	-0.2	1.8	
		23.1	-0.2	1.0	-1.4	
		168.9	1.8	-1.4	10.2	
9	345	167.9	32.2	-15.7	14.4	
		52.8	-15.7	135.4	-41.3	
		231.4	14.4	-41.3	89.5	
10	2494	87.9	17.5	-0.2	13.5	
		27.0	-0.2	7.9	-2.6	
		153.0	13.5	-2.6	80.6	
11	5666	86.4	8.7	4.9	-15.8	
		13.4	4.9	3.7	-13.0	
		145.1	-15.7	-13.0	51.0	

4. REZULTATI RASPOZNAVANJA OBLAČNIH SISTEMA

Provjera rezultata klasifikacije oblaka primijenjenog na podacima satelita NOAA 7 povezana je s poteškoćom dobivanja podataka o stvarnoj prirodi pojava i klasa — »ground truth«, odnosno podataka na osnovi kojih se može izvršiti ocjena rada klasifikatora. Uobičajene metode ocjene točnosti klasifikatora temelje se na usporedbi razvrstanih uzoraka u klase i poznatog broja elemenata klase koje se određuju. Metoda se primjenjuje za ocjenu rada klasifikatora koji identificiraju vrste podloge tla na temelju satelitskih slika — npr. Pettinger (1982). Zbog nedostatka podataka tog karaktera pristupilo se posrednoj metodi ocjene rada klasifikatora putem analize parametara funkcije diskriminacije, odnosno udaljenosti među klasama. Uočeno je da dolazi do pogrešne klasifikacije kod klasa čije je Jeffries-Matusita (J-M) udaljenost mala, odnosno kad vrijednosti funkcije J-M udaljenosti u ovisnosti o normaliziranoj udaljenosti padnu lijevo od teoretske funkcionalne veze J-M i normalizirane udaljenosti, Lipovšćak (1986).

Postupak klasifikacije odvijao se na dva načina. prvi algoritam definiran je jednadžbom (6) uz a priori vjerojatnost pojave klase jednake jedinici za sve klase. Drugi je algoritam modificirana varijanta algoritma klasifika-

cije u kojoj su uvedeni pragovi vjerojatnosti za svaku funkciju diskriminacije definirani postupkom (9). Klasifikator odbacuje sve vrijednosti funkcije diskriminacije manje od vrijednosti zadane pragom vjerojatnosti i svrstava ih u klasu nepoznatog porijekla. Na taj način dolazi do odbacivanja vrijednosti mjerenja onih pojava koje klasifikator nije naučio raspoznavati ili koja odstupaju od vrijednosti parametara funkcije diskriminacije više od zadanog praga. Pri tom postupku primijenjena je vrijednost praga 0.05 kao vrijednost svrstavanja elemenata u klasu nepoznatog porijekla.

Klasifikator oblaka svrstava oblake u klase označene brojevima od 1 do 12. Nakon razvrstavanja svaki se element slike prikazuje intenzitetom sive skale od 1 do 12, (4 bita) na ekranu rezolucije 512×512 točaka. Postupkom raspoznavanja klasa broj podataka znatno se reducira, od maksimalnog broja raspoloživih podataka za svaki element slike, 3×8 bita, postupkom se dobiva 1×4 bita informacije za svaki element slike. Prikazivanje slike na monitoru u boji omogućeno je postupkom pridjeljivanja boja vrijednostima sive skale. Svakoj vrijednosti sive skale od 1 do 12, koja odgovara nekoj od klasificiranih vrsta oblaka i pojava, pridijeljena je boja.


Za lakše raspoznavanje klasa pojava nakon klasifikacije izrađen je program koji na klasificiranu sliku nanosi skalu boja koje se pridjeljuju pojedinoj klasi. Skala boja nanosi se na donji rub slike s rastućim vrijednostima klasa udesno.

Nakon učenja klasifikatora izvršeno je raspoznavanje vrsta podloge i rodova oblaka na slikama 1 i 2. Za identifikaciju je primijenjena trodimenzionalna normalna razdioba kao funkcija diskriminacije, a u postupku su upotrebljeni parametri funkcije diskriminacije prema tablici 3. Raspoznavanje je vršeno u devet klasa pojava i oblaka. Dvije klase *Nimbostratus* (3) i *Altostratus* (4) – klasifikator u ovom stupnju razvoja još nije mogao raspoznati zbog nedostatka reprezentativnih uzoraka tih klasa na slikama za učenje.


Rezultat raspoznavanja prvog odabranog područja bez primjene praga vjerojatnosti prikazana je slikom 11. Klasifikator raspoznaje karakterističan oblačni sistem *Cumulonimbusa* (1) povezan sa *Cirusima* (6) i *Cumulus-congestusima* (2) u središnjem donjem dijelu slike. Raspoznate su i klase oblaka *Altostratus* (5) u središnjem gornjem dijelu slike, te sistem *Cirusa* u gornjem desnom kutu slike. Slojevita naoblaka zauzima gornji lijevi dio slike i sastoji se od sistema: *Cumulus-congestus*, *Stratocumulus* (7) i *Altostratus*. Središnji dio slike prikazuje morsku površinu (11) iznad koje se nalazi sistem *Cumulusa* (7) lijepog vremena. Karakteristična je pojava tla (10) otoka Sumatra, koje se na slici jasno raspoznaje, dok je na izvornoj satelitskoj slici tlo vidljivo jedino na podacima kanala 4 satelitskog skenera.

Upotrebom postupka u kojem je primijenjen prag vjerojatnosti pojavljuje se klasa nepoznatog porijekla na rubovima oblačnih sistema, te u području slojevite naoblake. Karakteristična je pojava klase nepoznatog porijekla na rubovima prozirnih cirusnih oblaka.


Histogram čestine pojave elemenata slike u pojedinoj klasi, nakon raspoznavanja prve odabrane slike, prikazan je za oba postupka raspoznavanja slikom 12. Razlika u broju razvrstanih elemenata slike u pojedine klase primjenom različitih postupaka klasifikacije je smanjenje broja elemenata klasa *Stratocumulus* (7), more (11) i tlo (10). Kod ostalih klasa ne dolazi do značajnog sma-



Slika 11. Rezultat klasifikacije satelitske slike prvog odabranog područja za devet klasa. Prag vjerojatnosti 0.



Slika 12. Histogrami čestine pojave klasa za klasificiranu sliku prvog odabranog područja. Raspoznavanje u devet klasa. a) prag vjerojatnosti 0;



b) prag vjerojatnosti 0.05.


njenja broja elemenata slike. Broj elemenata slike svrstanih u klasu oblaka Cumulonimbus (1) i Cumulus-congestus (2) gotovo je identičan u oba postupka raspoznavanja.

Rezultati primjene postupka raspoznavanja na podatke drugog odabranog područja bez primjene praga vjerojatnosti prikazani su slikom 13. Postupkom su raspoznate pojave klasa Cumulus-congestus (2), Stratocumulus (7), Altostratus (5), Cirus (6), tlo (10) i more (11). Karakteristika je raspoznavanje klase prozirnih Cirusa (6) koji se javljaju nad istočnom obalom prevlake Kra, a ispod kojih se raspoznaje sloj Stratocumulusa i Altostratusa. Na zapadnoj obali prevlake Kra raspoznat je sistem Stratocumulusa (7). Granica tla i mora dobro je izražena, što nije osobina sirovih satelitskih slika na kojima je gotovo nemoguće odrediti granicu kopna i mora u vidljivom i infracrvenom području. Središnji donji dio slike sastoji se od slojevite naoblake u kojoj dominira sistem Cumulus-congestusa, okruženog cirusnom naoblakom. Donji kat slojevite naoblake čini sistem Stratocumulusa.

Histogrami čestine pojave elemenata slike u pojedinoj klasi nakon primjene postupka raspoznavanja, sa i bez praga vjerojatnosti, prikazani su slikom 14. Uočava se porast broja elemenata slike svrstanih u klasu nepoznatog porijekla na račun broja elemenata slike svrstanih u klase Stratocumulus (7) i Cirus (6). Promjena bro-



Slika 13. Rezultat klasifikacije satelitske slike drugog odabranog područja za devet klasa. Prag vjerojatnosti 0.





Slika 14. Histogrami čestine pojave klasa za klasificiranu sliku drugog odabranog područja. Raspoznavanje u devet klasa.

a) prag vjerojatnosti 0;

ja elemenata slike svrstanih u klasu Cumulus-congestus (2) i Altostratus (5) neznatna je.

Rezultat primjene postupka raspoznavanja bez praga vjerojatnosti na trećem odabranom području prikazan je na slici 15, raspoznaju se pojave klasa: tlo (10), snijeg (9), magla (8) i Stratocumulus-Cumulus (7). Primjenom postupka raspoznavanja bez praga vjerojatnosti na klasificiranoj slici pojavila se i klasa oblaka Cirus (6). Postupkom raspoznavanja koji primjenjuje prag vjerojatnosti su elementi slike u prvoj klasifikaciji prikazani



Slika 15. Rezultat klasifikacije satelitske slike trećeg odabranog područja za devet klasa. Prag vjerojatnosti 0.


kao Cirusi — svrstani u klasu nepoznatog porijekla. Postupkom raspoznavanja bez primjene praga vjerojatnosti dolazi do svrstavanja elemenata slike u klasu

Stratocumulus-Cumulus (7), iako toliko naoblake te vrste na slici nije bilo. Upotrebom postupka s pragom vjerojatnosti većina je tih elemenata slike svrstana u klasu nepoznatog porijekla.


Histogrami čestine pojava elemenata slike, nakon primjene postupka raspoznavanja treće odabrane slike, u određenoj klasi prikazani su na slici 16. Primjenom postupka raspoznavanja s pragom vjerojatnosti dolazi do smanjenja broja elemenata slike koji su svrstani u klasu naoblake. Broj elemenata slike svrstanih u klasu snijeg (9) nije se značajno promijenio. Velik broj elemenata slike svrstanih u klase Stratocumulus-cumulus (7) svrstani su u klasu nepoznatog porijekla. Klasa Cirrus (6) potpuno nestaje nakon raspoznavanja s primjenom praga vjerojatnosti.

4.1. REZULTAT RASPOZNAVANJA OBLAKA I POJAVA NA SLICI ORBITA BROJ 12522


Treći je korak u provjeri rada automatskog klasifikatora oblaka raspoznavanje oblaka i pojava na slikama koje prikazuju prelet satelita orbitom broj 12522. Prilikom raspoznavanja korištena su oba postupka — sa i bez primjene praga vjerojatnosti. Za prag vjerojatnosti u raspoznavanju odabrana je vrijednost 0.05.



Slika 16. Histogrami čestine pojave klasa za klasificiranu sliku trećeg odabranog područja. Raspoznavanje u devet klasa. a) prag vjerojatnosti 0;




b) prag vjerojatnosti 0.05.



PROJECT INTERACT
SATELITE
DATE: 05-12-88
CHANNEL: 0
ORBIT: 12522
CLASSIFIED: UNCLASSIFIED 0.05. 3x3

Slika 17. Rezultat klasifikacije u devet klasa — oblaci, kopno i more slike primljene u vidljivom, blizu infracrvenom i infracrvenom dijelu spektra od satelita NOAA7 za vrijeme preleta orbitom br 12522.

a) prag vjerojatnosti 0.



b) prag vjerojatnosti 0.05.

Raspoznavanje je izvedeno s parametrima funkcije diskriminacije definiranim vrijednostima iz tablice 3 za 9 klasa pojava. Na klasificiranim slikama raspoznaje se 6 klasa oblaka, tlo i more. Primjenom pravila raspoznavanja koje uključuje prag vjerojatnosti na klasificiranoj slici pojavljuje se klasa nepoznatog porijekla. Rezultati primjene pravila raspoznavanja prikazani su slikom 17 a, b. Osobina obiju slika je raspoznavanje klase tlo (zeleno) u gornjem desnom kutu slike. Raspoznaje se područje Indokine s jasno izraženim južnim rtom Vijetnama i prevlakom Kra u središnjem dijelu slike. Značajni oblaci sistemi koji su na slici raspoznati su linija Cumulonimbusa (crveno) u lijevom dijelu slike, koja je okružena naoblakom roda Cumulus-congestus (svijetlo ljubičasto) i Stratocumulus (žuto). Središnji dio slike svrstan je u klasu more (tamno plavo); nad morem se proteže u obliku pera sloj Cirusa (svijetlo plavo). Raspoznavanjem uz primjenu praga vjerojatnosti je dio elemenata slike svrstanih u klasu (7), svrstano u klasu nepoznatog porijekla.

Primjena pravila raspoznavanja uz upotrebu podataka tri kanala mjerenja satelita NOAA 7 dala je ohrabrujuće rezultate. Pogrešna klasifikacija javlja se u slučaju klasa kod kojih je iznos normalizirane i J-M udaljenosti među parametrima funkcije diskriminacije mali, Lipovšćak (1986). Do pogrešne klasifikacije upotrebom pravila definiranog jednadžbom (6), bez upotrebe praga vjerojatnosti, dolazi zbog svrstavanja podataka u klasu koja je najbliža izračunatoj vrijednosti funkcije diskriminacije. Uvođenjem pragova vjerojatnosti definiranih postupkom (9) sve izračunate vrijednosti funkcije diskriminacije manje od zadanog praga svrstane su u klasu nepoznatog porijekla. Na taj način klasifikator svrstava rubna područja između različitih tipova oblaka i pojava koja imaju karakteristike obje pojave u pojavu nepoznatog porijekla. Stoga su na slici 17 b poznate pojave okružene crnim rubom koji predstavlja prijelaznu zonu između dviju karakterističnih pojava.

5. ZAKLJUČAK

Postupak raspoznavanja oblaka i pojava na temelju satelitskih slika visoke moći razlučivanja koji je prikazan u ovom radu je nakon provjere i prevođenja programa sa standardnog Fortrana u AP rutine uključen u pa-

ket programa ranog otkrivanja opasnih meteoroloških pojava koji su razvijeni okvirom projekta INTERACT.

Vrijeme potrebno za automatsku klasifikaciju slike koja sadrži 512×512 elemenata u tri kanala je primjenom array procesora svedeno na 8 minuta, dok je klasifikacija s izvornim programom pisanim u standardnom Fortran jeziku trajala cca. 170 minuta.

Prikaz klasificirane satelitske slike oblaka i pojava na kolor monitoru uz označavanje klasa skalom boja na dnu ekrana omogućuje lako raspoznavanje položaja i vrsta naoblake. Program za raspoznavanje oblaka i pojava u ovom stupnju razvoja programskog paketa nije povezan s programima za »navigaciju« slike koji omogućuju točnu geografsku lokaciju klasificirane pojave. U operativnoj primjeni program za automatsko raspoznavanje oblaka i pojava sa satelitskih slika idući je korak spajanje tih dvaju programskih paketa.

Primjena klasificiranih slika naoblake u klimatologiji oblaka i oblačnih sistema omogućit će dobivanje statistike godišnje, mjesečne i tjedne količine naoblake nad određenim područjem. Važnost je ovog vida primjene klasificiranih satelitskih slika dobivanje podataka s područja nad kojim tih podataka do sada nije bilo, što omogućuje bolje i potpunije poznavanje radiacione bilance Zemlje.

Primjena klasificiranih satelitskih slika oblaka namijenjena je osoblu neškoloivanom za analizu meteoroloških satelitskih podataka u izvornom obliku. Ovdje se u prvom redu misli na primjenu u mornarici, avijaciji, prometu i poljoprivredi. Za meteorološki kadar klasificirana satelitska slika znači doprinos pouzdanosti prognoze i ranom otkrivanju opasnih meteoroloških pojava.

Klasificirana slika oblaka omogućuje znatno smanjenje broja informacija koje je potrebno prenijeti do krajnjeg korisnika slike, uz zadržavanje osnovnih karakteristika meteoroloških sistema. Smanjenje broja informacija (element klasificirane slike prikazan je sa 4 bita informacije) omogućuje lakše arhiviranje podataka za kasniju upotrebu i analizu.

Klasifikator oblaka izveden je tako da se može primijeniti za raspoznavanje oblaka i pojava iz podataka meteoroloških satelita sa svih geografskih širina. Za klasifikaciju nisu potrebni dodatni podaci meteoroloških mjerenja vertikalnog stanja atmosfere već je dovoljan reprezentativan skup podataka za učenje klasifikatora. Proces učenja klasifikatora nikad nije završen jer je moguće noveliranje baze podataka parametara funkcije diskriminacije među klasama.

Postupak raspoznavanja oblaka i pojava moguće je primijeniti za klasifikaciju satelitskih podataka prikazanih mjerenjem jednog, dva ili tri kanala skenera. U postupku klasifikacije ovisno o raspoloživom broju kanala podataka, upotrebljava se jedno-, dvo- ili tro-dimenzionalna normalna razdioba kao funkcija diskriminacije među klasama.

Postupak raspoznavanja oblaka i pojava uz promjenu funkcija diskriminacije među klasama može se upotrijebiti i za klasifikaciju ostalih digitalnih slika visoke rezolucije, naprimjer, u medicini, obradi podataka ostalih satelita, obradi radarskih slika itd.

Klasifikator je testiran i za klasifikaciju podataka LANDSAT satelita kanala 4, 5 i 6, (Lipovšćak 1986).

SAŽETAK

Kratkoročna prognoza vremena (nowcasting) povezana je s potrebom za vrlo čestim meteorološkim osmatranjima satelita omogućuje neprekidno praćenje vremena nad velikim prostranstvima Zemlje.

U radu su prikazani prvi rezultati primjene programa za automatsku klasifikaciju satelitskih slika oblaka i podloge. Kao ulazni podaci za klasifikaciju oblaka korišteni su visoko rezolutni podaci satelitskog skenera AVHRR (Advanced Very High Resolution Radimometer) meteorološkog satelita NOAA.

Rezultati satelitskih mjerenja pojedinih rodova i vrsta oblaka u nekom području valnih duljina spektra mogu se prikazati normalnom razdiobom. Korišteni su podaci tri kanala satelitskog skenera te je upotrijebljena trodimenzionalna normalna razdioba kao funkcija diskriminacije.

Za klasifikaciju oblaka na osnovi digitalnih podataka satelitskog skenera velike moći razlučivanja primijenjen je klasifikator tipa maksimalne vjerojatnosti (maximum likelihood). Postupak klasifikacije izvršen je primjenom dva algoritma: upotrebom Bayesova pravila maksimalne vjerojatnosti i algoritmom u kojem su ugrađene ganične vrijednosti (pragovi) koji definiraju vjerojatnost da je pojava iz određene klase.

Prag vjerojatnosti je veličina koja je granična za pridjeljivanje nekog podatka određenoj klasi. Definira se unaprijed, prije postupka identifikacije, i to za svaku klasu posebno ili za sve klase jednakim iznosom. U radu je korišten prag vjerojatnosti 0.05, a algoritam za klasifikaciju svrstava sve elemente slike za koje je vjerojatnost funkcije diskriminacije manja od praga u klasu nepoznatog porijekla.

Klasifikator oblaka svrstava oblake u klase označene brojevima od 1 do 12. Nakon razvrstavanja svaki se element slike prikazuje određenom bojom na ekranu grafičkog računala. Postupkom klasifikacije reducira se broj podataka koji je potrebno prenijeti korisniku satelitske slike. Od maksimalnog broja raspoloživih podataka za svaki element slike, 3×8 bita, postupkom se dobiva 1×4 bita informacije za svaki element slike.

LITERATURA

Anderson R. K., E. W. Ferguson, V. J. Oliver, 1966: The use of satellite pictures in weather analysis and forecasting, WMO Tech. No. 75, 183 pp.

Barens J. C., D. Chang, 1968: Accurate cloud cover determinations and its effects on albedo computations, Final Report, NASS-104780 Concord Mass., Allied Res. Ass., Inc., 82 pp.

Bizzari B., C. Tomassini 1876: Retrieval of information from high resolution images, Proc. Syn. Met. Obs. from Space: Thier Contrib. to FGGE, COSPAR XIX, Philadelphia, 140–144.

Both A. L., 1973: Objective cloud type classification using visual and infrared satellite data, Tech. No. BN-768, College Park, University of Maryland, 62 pp.

Cailla F. R., 1978: Determination de la temperature de Cirrus semitransparents, La Meteorologie, 15, Decembre, 63–67.

Coakley J. A., D. G. Baldwin, 1984: Towards the objective analysis of clouds from satellite imagery data, Jou. of Clim. and App. Met., Vol. 23, 1065–1099.

Conover J. H., 1962: Cloud interpretation from satellite altitudes, air Force Cambridge Research Lab., AFCRL-62-680. 77 pp.

Desbois M., G. Seze, G. Szezwach, 1982: Automatic classification of clouds on METEOSAT imagery: application to high level clouds, Jou. Of App. Met., Vol. 21, 401–412.

- Grcaves J. I., D. Chang, 1970: Technique development permit optimum use of satellite radiation data, Final Report, N62306-69-0-002 Concord Mass., Allied Res. Associ., Inc., 102 pp.
- Harris R., E. C. Barret 1975: An improved satellite nephanalysis, *Met. Magazine*, Vol. 104, 9–16.
- Kondratjev K. J., E. P. Borisenko, A. A. Marozkin, 1966: Praktičeskoe ispolzovanje danih meteoroloških sputnikov, *Gidrometeoizdat, Leningrad*, 251–256.
- Lee R., C. I. Taggart, 1969: A procedure for satellite cloud photo-interpretation, and appearance of clouds from satellite altitudes in satellite imagery, *Bureau of Meteor., Malburne*, 17 pp.
- Liljas E., 1981: Automated techniques for satellite imagery analysis, *Proceedings, IAMP Symp., Hamburg*, 331–339.
- Liljas E., 1984: Processed satellite imageries for operational forecasting, *SMHI, Norrköping*, 43 pp.
- Lipovščak B., 1983: Pattern recognition in meteorological satellite imagery, *CMC Techn. Digest, Secunderabad-India*, Vol. 5., No. 8, 17–19.
- Lipovščak B., 1983a: Accomplishment report on the development of pattern recognition system, *CMC-INTERACT*, nepublicirano, 34 pp.
- Lipovščak B., 1984: Digital image processing system for meteorological satellites INTERACT approach, *RHMZ SRH, Rasprave* 19, 75–78.
- Lipovščak B., 1985a: Automatska klasifikacija satelitskih meteoroloških podataka oblaka, *PPPR Zagreb*, 347–352.
- Lipovščak B., 1985b: Sateliti u meteorologiji, *Pomorska enciklopedija*, Vol. 7, JLZ, Zagreb, 204–206.
- Lipovščak B., Bojan, 1986: Identifikacija oblačnih sustava na temelju numeričkih satelitskih podataka, *Doktorska disertacija, Sveučilište u Zagrebu*, 148.
- Lipovščak B., 1987: Primjena klasifikatora satelitskih slika oblaka u klasifikaciji podloge, *Jugoslavenska akademija znanosti i umjetnosti, Savjet za daljinska istraživanja i fotointerpretaciju, Zagreb* Vol. 1, Br. 8, 79–84.
- Lo R. C., D. R. Johnson, 1971: An investigation of cloud distribution from satellite infrared radiation data, *Mon. Wea. Rev.*, Vol. 99, 599–605.
- Mehrtre B. M., N. N. Murthy, B. Lipovščak, B. Chatterjee 1985: Automatic Cloud classification, *Int. Geosci. and Remote Sens. Symp. IGARSS'85, Amherst, Mass., Oct. 7–9, 1985*, New York, 233–241.
- Mehrtre B. M., B. Lipovščak, N. N. Murthy, B. Chatterjee 1986: Automatic cloud classification, *IETE Tech. Rev.*, New Delhi, India, Vol. 3, No. 6, 272–278.
- Parikh J. A., J. T. Ball, 1980: Satellite cloud analyses for a radiation model, *Pattern recognition in practice*, North-Holland Pub. Co., Amsterdam, 201–212.
- Parikh J. A., A. Rosenfeld 1978: Automatic segmentation of infrared meteorological satellite data, *IEEE Trans. on Sys.*, Vol. SME-8, No. 10, 736–743.
- Pettinger L. R., 1982: Digital classification of Landsat Data for Vegetation and Land — Cover Mapping in the Blackfoot River Watershed, Southeastern Idaho, *Geol. survey prof. pap.* 1219, US Gov. Print. Off., Washington, 33 pp.
- Rao P. K., 1970: Estimating of cloud amount and height from satellite IR radiation data, *ESSA Techn. Rep.*, NESC 54, 11 pp.
- Raynolds J. W., T. H. Vander Haar, 1977: A bispectral method for cloud parameter determination, *Mon. Wea. Rev.*, Vol. 105, 446–457.
- Raynolds J. W., M. L. Brown, E. A. Smith, T. H. Vander Haar, 1978: Cloud type separation by spectral differencing of image pairs, *Mon. Wea. Rev.*, vol. 106, 1214–1218.
- Shenek W. E., R. J. Holub, R. A. Neff 1976: A multispectral cloud type identification method developed for tropical ocean areas with NIMBUS-3 MRIR measurements. *Mon. Wea. Rev.*, vol. 104, 284–291.
- Smith E. A., T. H. Vander Haar, J. Graffy, 1981: The impact of GOES satellite data compaction on the estimates of cloud parameters, *Rep. Worksh. on Clouds and Climat., NASA God. Ins. for Space Stud.*, 192–196.
- Simmer C., E. Raschke, E. Ruprecht, 1982: A method for determination of cloud properties from two-dimensional histograms, *Ann. Meteor.*, 18, 130–132.
- Szeywach G., M. Desbois, 1978: Dynamic classification of mesoscale cloud patterns, *Jou. App. Met.*, Vol. 17, 1406–1411.
- WHO, 1984: Cloud analysis algorithm intercomparison, *ISCP, WCP-3*, 74 pp.

ABSTRACT

The use of meteorological data for very short range weather forecasting (nowcasting) is connected with the need for a high number of classical meteorological observation data. The use of meteorological satellite enables the continuous weather monitoring over large areas of the Earth.

First results of the automatic cloud and underlying surface classification of NOAA-7 satellite data is presented. The input data for the cloud classification are the high resolution NOAA-7 satellite data. AVHRR (Advanced Very High Resolution Radiometer) measures the radiation in five spectral bands: visible (channel 1 and 2), near infrared (channel 3) and infrared (channel 4 and 5).

The results of satellite measuring of cloud types in one spectral area can be represented by normal distribution. Multivariate normal density function is used as a discriminant function for cloud separation and identification of Earth surface from clouds.

Maximum likelihood classifier is applied for the digital data classification. The classification is made with two algorithms using the Bayes rule of maximum likelihood and the threshold method. Threshold is a boundary value which defines the belonging of data to a defined class. Threshold is defined in advance, prior to the classification, separately for each class, or with a constant value for all classes. Threshold 0.05 is used and all the values of discrimination functions which are minor to the threshold value are classified in the reject class.

The cloud classifier classifies the clouds in classes marked with numbers from 1 to 12. Following the classification every pixel is presented by a defined colour on the computer screen. During the classification the amount of data is reduced. From the maximum number of data for every pixel, a 3 × 8 bit, the classification reduces the amount to a 1 × 4 bit for every pixel.