

# Identifikacija vodenih površina na satelitskim snimcima neuralnom mrežom

---

**Barbalić, Darko; Rajčić, Vlatka**

*Source / Izvornik:* **Građevinar, 2003, 55, 513 - 518**

**Journal article, Published version**

**Rad u časopisu, Objavljena verzija rada (izdavačev PDF)**

*Permanent link / Trajna poveznica:* <https://um.nsk.hr/um:nbn:hr:237:589152>

*Rights / Prava:* [In copyright](#) / [Zaštićeno autorskim pravom.](#)

*Download date / Datum preuzimanja:* **2024-10-07**

*Repository / Repozitorij:*

[Repository of the Faculty of Civil Engineering,  
University of Zagreb](#)



# Identifikacija vodenih površina na satelitskim snimcima neuralnom mrežom

Darko Barbalić, Vlatka Rajčić

## Ključne riječi

GIS,  
neuralna mreža,  
daljinsko motrenje,  
klasifikacija,  
vodene površine

D. Barbalić, V. Rajčić

Prethodno priopćenje

## Identifikacija vodenih površina na satelitskim snimcima neuralnom mrežom

*U radu je opisana jedna od mogućnosti utvrđivanja obuhvata vodenih površina sa satelitskog snimka korištenjem neuralne mreže. Usporedba s ručnom klasifikacijom na ispitivanom području pokazalo je vrlo dobro slaganje rezultata. S obzirom na to da postoje otvorene mogućnosti daljnjih unapređenja većine elemenata te unapređenja ukupnog koncepta, autori su uvjereni da bi se mogli dobiti još bolji i pouzdaniji rezultati te bi svakako bilo uputno nastaviti istraživanja na tom planu.*

## Key words

GIS,  
neural network,  
remote sensing,  
classification,  
water surfaces

D. Barbalić, V. Rajčić

Preliminary note

## Identification of water surfaces on satellite photographs by neural network

*A possibility of using neural networks to determine the extent of water surfaces shown in satellite photographs, is described in the paper. Comparison with manual classification in the same area shows a very good correspondence of results. As there are ample possibilities for developing an overall concept and most of its elements, authors believe that current results could be improved and made more reliable and, consequently, that further investigations in this fields are highly warranted.*

## Mots clés

GIS,  
réseau neuronal,  
télétection,  
classification,  
surfaces aquatiques

D. Barbalić, V. Rajčić

Note préliminaire

## Identification des surfaces aquatiques sur les images satellitaires par un réseau neuronal

*L'article décrit l'une des possibilités de détermination de l'étendue des surfaces aquatiques grâce à l'imagerie satellitaire par l'utilisation d'un réseau neuronal. Une comparaison avec la méthode de classification manuelle dans le périmètre étudié a révélé une très bonne concordance des résultats. Compte tenu des possibilités ouvertes d'améliorations de la plupart des éléments et d'amélioration de l'ensemble du concept, les auteurs sont persuadés qu'on pourrait obtenir de meilleurs résultats et encore plus fiables et qu'il serait utile de poursuivre les recherches sur ce plan.*

## Ключевые слова

GIS (ГИС),  
невральная сеть,  
наблюдение из космоса,  
классификация,  
водные поверхности

Д. Барбалич, В. Райчиц

Предварительное сообщение

## Идентификация водных поверхностей на спутниковых снимках невральной сетью

*В работе описана одна из возможностей установления охвата водных поверхностей с спутникового снимка при использовании невральной сети. Сравнение с классификацией вручную на исследуемой территории показало очень хорошее совпадение результатов. Принимая во внимание то, что существуют открытые возможности дальнейшего развития большего числа элементов, а также развития полного концепта, авторы уверены, что бы могли быть получены ещё лучшие и более надёжные результаты, так что было бы целесообразно продолжить исследования на том плане.*

## Schlüsselworte:

GIS,  
Neuralnetz,  
Fernmonitoring,  
Klassifizierung,  
Wasserflächen

D. Barbalić, V. Rajčić

Vorherige Mitteilung

## Identifikation von Wasserflächen auf Satellitenaufnahmen mittels Neuralnetz

*Im Artikel beschreibt man eine der Möglichkeiten den Umfang der Wasserflächen auf Satellitenaufnahmen festzustellen, und zwar durch Benützung des Neuralnetzes. Ein Vergleich mit der manuellen Klassifizierung am untersuchten Gebiet zeigte eine sehr gute Übereinstimmung der Ergebnisse. Da offene Möglichkeiten weiterer Förderungen eines Grossteils der Elemente, sowie auch des gesamten Konzepts, bestehen, sind die Verfasser überzeugt dass man noch bessere und zuverlässigere Ergebnisse erreichen könnte, so dass es vorteilhaft wäre diese Forschungen weiter zu führen.*

Autori: **Darko Barbalić**, dipl. ing. građ, Zavod za vodno gospodarstvo, Hrvatske vode, Ul. grada Vukovara 220, Zagreb; doc. dr. sc. **Vlatka Rajčić**, dipl. ing. građ., Građevinski fakultet Sveučilišta u Zagrebu, Kačićeva 26

### 1 Uvod

U okviru vodnog gospodarstva često se ukazuje potreba za utvrđivanjem područja vodenih površina. Primjene mogu biti mnogostruke, a neke su od njih prikupljanje osnovnih podloga za potrebe vodnogospodarskog planiranja, praćenje dinamike poplava, praćenje promjena na vodnom dobru (npr. iskop šljunka) i slično.

Danas postoje različiti načini pribavljanja takvih podloga, a jedna je od mogućnosti daljinsko motrenje, u ovom slučaju satelitskog snimanja.

Neke su od prednosti satelitskih snimanja i:

- velika površina snimke zahvaćena u jednom trenutku
- digitalna forma
- mala jedinična cijena snimke (cijena po jediničnoj površini)
- mogućnost uporabe snimke za različite namjene
- mogućnost cikličkih snimanja u vrlo kratkim vremenskim razdobljima i nabave "povijesnih" snimaka.

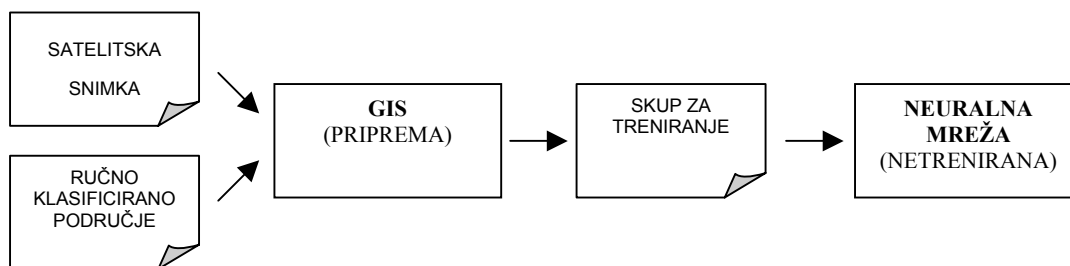
Da bi se identificirale vodene površine, satelitske je snimke potrebno "klasificirati", tj. u ovom slučaju podijeliti na "površine pod vodom" i "ostale površine".

Postojeći programski paketi za klasifikaciju satelitskih snimaka najčešće se zasnivaju na složenim statističkim algoritmima (mahalanobisova udaljenost, metoda najveće vjerodostojnosti i slično). U ovom je radu prikazana mogućnost preliminarne klasifikacije satelitskih snimaka, i to uz pomoć neuralne mreže.

### 2 Osnovne postavke

Postupak klasifikacije satelitske snimke sastoji se od sljedećih koraka:

- ručno definiranje položaja vodenih površina s poznatim prostornim područjem (pripremanje podataka za kalibraciju neuralne mreže)
- formiranje skupa podataka za treniranje neuralne mreže na osnovi definiranih vodenih površina te treniranje neuralne mreže (kalibriranje neuralne mreže)
- klasificiranje ostatka satelitske snimke istreniranom neuralnom mrežom.



Slika 1. Treniranje neuralne mreže - definiranje funkcije klasifikacije satelitske snimke

Satelitska snimka sastoji se od jednog ili više kanala koji se prostorno preklapaju. Svaki je od ovih kanala pravokutna matrica s cjelobrojnim vrijednostima između 0 i 255. Prostorno, svakom elementu matrice na tlu pripada kvadrat određene veličine. Drugačije rečeno, svaka točka na tlu definirana je *n*-dimenzionalnim vektorom (*n* - broj kanala) čije komponente mogu imati cjelobrojne vrijednosti od 0 do 255.

Da bi se omogućilo izdvajanje vodenih površina sa satelitske snimke, snimku je potrebno klasificirati, tj. svakom prostornom elementu dodijeliti vrijednost 0 - nije vodena površina ili 1 - vodena površina. Drugačije rečeno, treba definirati funkciju

$$(x_1, \dots, x_n) \rightarrow f(x_1, \dots, x_n) \text{ pri čemu}$$

$$x_i \in \{0, 1, \dots, 255\}, \quad i = 1..n$$

gdje je *n* broj kanala satelitske snimke,

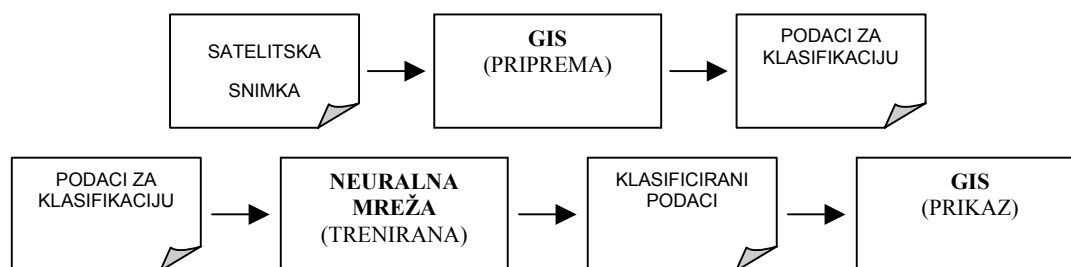
$$a \ f(x_1, \dots, x_n) \in \{0, 1\}$$

(1 - vodene površine, 0 - ostale površine)

Definiranje funkcije  $(x_1, \dots, x_n) \rightarrow f(x_1, \dots, x_n)$  koja bi vrijedila za više satelitskih snimaka različitih karakteristika vrlo je složen problem te se u praksi definira posebna funkcija za svaku snimku posebno. U okviru ovog rada, definiranje ove funkcije prepušteno je neuralnoj mreži.

Neuralna je mreža sustav za procesiranje informacija koji se bazira na generalizaciji ljudskog poimanja. Procesiranje informacija obavlja se u velikom broju jednostavnih, međusobno povezanih elemenata "neurona" koji razmjenjuju signale. Svaka veza dvaju neurona ima svoju "težinu" – multiplikator jačine signala koji se njome prenosi, a na osnovi ulaznih signala pojedini neuron "aktivacijskom funkcijom" određuje izlazni signal. Jedna od najbitnijih karakteristika neuralne mreže jest mogućnost "nadziranog" učenja na primjerima, to jest. samoprilagodavanja "težina" pojedinih veza radi minimizacije greške izlazne vrijednosti. U ovom se slučaju "treniranjem" neuralne mreže se definira funkcija klasifikacije satelitskog snimka  $(x_1, \dots, x_n) \rightarrow f(x_1, \dots, x_n)$  (slika 1.).

OVAKO istrenirana neuralna mreža nadalje služi za klasifikaciju ostatka satelitskog snimka (slika 2).



Slika 2. Klasifikacija satelitske snimke

### 3 Primjer

Za potrebe ovog rada upotrijebljena je LANDSAT7 (ETM) satelitska snimka snimljena 2. 8. 2000. Površina koju snimka pokriva jest otprilike 33270 km<sup>2</sup> (slika 3.).




Slika 3. Područje satelitske snimke

Snimka se sastoji od ukupno 8 kanala čije prostorne razlučivosti variraju između 15 i 60 m, a ukupni raspon svjetlosnog spektra je 0,45 – 12,5 mikrona. Prostorna je razlučivost u radu svedena na jedinstvenu za sve kanale od 30 m.


Za manipulaciju satelitskom snimkom, ručnu digitalizaciju te formiranje potrebnih skupova podataka čitljivih za neuralnu mrežu (tekstualna datoteka) korišteni su standardni GIS alati. Isti su alati upotrijebljeni i za transformaciju rezultata rada neuralne mreže (tekstualna datoteka) u standardne prostorno referencirane GIS formate (slike). Uporabljena je javno dostupna neuralna mreža koja omogućuje vrlo jednostavnu integraciju te su formirane odgovarajuće rutine za rad.

Da bi se omogućilo formiranje skupa podataka za trening neuralne mreže, odabran je mali dio (1,6 km<sup>2</sup>) satelitskog snimka, za koji postoji vrlo precizna i vizualno jasna georeferencirani ortofotografska snimka približno jednake starosti kao i satelitska. Vizualnom interpretacijom ovog snimka, odabrano područje je ručno podijeljeno na vodene (vrijednost 1) i ostale (vrijednost 0) povr-

šine (tzv. poligone) (slike 4.a – 4.d). Ovako definirane površine prevedene su u rastersku matricu koja prostorno odgovara matrici elemenata satelitske snimke. Svakom je elementu matrice osim vrijednosti dodijeljena ručnom klasifikacijom u prethodnom koraku dodijeljena i odgovarajuća vrijednost svih osam kanala satelitske snimke. Time je formiran skup podataka za treniranje neuralne mreže od ukupno 1771 elementa ("primjera"), od čega je 413 klasificirano kao "vodene površine", a ostatak kao "ostale površine".



Slika 4.a Aerofotografski snimak Slika 4.b Satelitska snimka



Slika 4.c Ručna interpretacija


Slika 4.d Skup podataka za treniranje neuralne mreže

Problem određivanja optimalnih parametara neuralne mreže (arhitektura, broj neurona, *learning rate*, *learning momentum*) vrlo je složen i ne postoji jedinstven način za njihovo određivanje. Na osnovi literaturnih podataka i ograničenja ovdje primijenjene neuralne mreže, odabrana je mreža s 200 neurona i 1500 epoha, dok je za *learning rate* i *learning momentum* formiran skup od 40 parova vrijednosti te je odabran onaj par koji je imao naj-

manju srednju kvadratnu razliku između točnih i proračunanih vrijednosti skupa podataka za treniranje.

Tako je u konačnici upotrijebljena *feed forward - back propagation* neuralna mreža s 200 neurona i 1500 epoha, *learning rate* 0,0008 i *learning momentum* 0,001.


S obzirom na to da neuralna mreža kao rezultat daje realni broj, a da je za potrebe klasificiranja potrebna diskretna vrijednost (u ovom slučaju 0 ili 1) da bi se odredila granica ( $g$ ) između ovih vrijednosti, primijenjen je princip najveće vjerodostojnosti (slika 5.), to jest odabrana je ona granica ( $g$ ) za koju je najveći broj elemenata skupa za trening točno klasificiran. Odabrana je vrijednost  $g = 0,393$ , pri čemu je točno klasificirano 90,8% elemenata.



Slika 5. Određivanje granice  $g$

#### 4 Rezultati


Da bi se mogla ocijeniti uspješnost klasifikacije satelitske snimke s pomoću neuralne mreže, napravljena je klasifikacija testiranog područja različitim metodama te su proračunane njihove statističke karakteristike. Za testirano je područje odabrano jezero Jarun s okolinom (slike 6.a i 6.b), površine ukupno 4,35 km<sup>2</sup> (matrica satelitske snimke veličine 82 x 59 elementa).



Slika 6a Aerofotografska snimka



Slika 6.b Satelitska snimka




Slika 6.c Ručna klasifikacija aerofotografske snimke



Slika 6.d Ručna klasifikacija

Slika 6.e. Klasifikacija uporabom neuralne mreže

Klasifikacija je izvršena ručnom klasifikacijom (slike 6.c i 6.d), klasifikacijom neuralnom mrežom (slika 6.e) te nadziranom klasifikacijom primjenom komercijalnoga programskog paketa (slika 6.f).



Slika 6.f Prethodna klasifikacija komercijalnim programskim paketom

Rezultati usporedbe klasifikacija snimaka sumirani su u tablici 1

Tablica 1. Različito klasificirane površine testiranog područja od ukupno 4838 elementa

		VODENE POVRŠINE		
		NM	RU	ST
OSTALE POVRŠINE	NM	-	2.3%	10.4%
	RU	1.0%	-	10.0%
	ST	0.2%	1.2%	-
NM		- klasifikacija uporabom neuralne mreže		
RU		- ručna klasifikacija		
ST		- predhodna klasifikacija komercijalnim softverom		
NAPOMENA:		vrijednosti odgovaraju broju elemenata (postotku u odnosu na cijelo testno područje) koji su različitim metodama klasificirani u različite klase		

## 5 Zaključak

U radu je opisana klasifikacija multispektralne satelitske snimke uporabom neuralne mreže. Usporedba s ručnom klasifikacijom pokazala je vrlo dobro slaganje - razlike na manje od 3% površine, dok su razlike u odnosu na klasifikaciju komercijalnim programskim paketom dosta veće. Vjerojatno je jedan od razloga i to što je u okviru te klasifikacije izvršeno razlučivanje na šest a ne na dvije klase.

Pri definiranju skupa podataka za treniranje trebalo bi posvetiti pažnju slijedećem:

- Optimiranju količine podataka, jer povećanje količine podataka, s jedne strane, zahtjeva više rada na njihovom formiranju i više vremena potrebnog za treniranje i određivanje parametara rada neuralne mreže, a s druge strane vrlo vjerojatno doprinosi većoj pouzdanosti rada.
- Heterogenosti površina koje treba izdvojiti u pojedine klase sa stajališta tehnologije satelitskog snimanja, što se vidi na ovdje odabranom primjeru. Očito je da se vizualno (prema boji) razlikuju šljunčara (žuto), rijeka (crno) i jezero Jarun (zeleno). Iako to u okviru ovog primjera nije predstavljalo problem za relativno točnu klasifikaciju, može se dogoditi da određene vodene površine imaju bitno drugačije karakteristike te da ne bi bile identificirane na ovaj način.
- Određeni je problem i određivanje granica između vodenih i ostalih površina jer su one promjenjive u vremenu (ovisne o vodostaju), tako da bi se za formira-

nje skupa za treniranje neuralne mreže trebale odabrati one vodene površine za koje se može što točnije utvrditi vodena površina u trenutku snimanja.

Veliku ulogu u ukupnoj primjeni neuralne mreže za klasifikaciju satelitskih snimaka imaju, naravno, i karakteristike same mreže. U ovom je slučaju uporabljena "standardna" *feed - forward, back propagation* neuralna mreža, ali bi svakako trebalo razmisliti o primjeni i testirati i druge moguće arhitekture kao na primjer Kohenenovu. Postavlja se i pitanje optimaliziranja veličine mreže, tj. broja neurona koji je čine, te određivanja parametara za njezino treniranje. Dakako sve su ove veličine i u uskoj vezi s karakteristikama seta podataka za treniranje i same satelitske snimke. U literaturi ne postoje precizne upute za određivanje karakteristika neuralnih mreža nego samo načelne preporuke. Vjerojatno bi se teorijskim i empirijskim istraživanjem na ovom polju mogli izvući neki manje uopćeni zaključci i time unaprijediti cjelokupni proces klasifikacije.

Problemi koji su se pojavili u najvećoj su mjeri sporost rada i nepostojanje nekih specifičnijih funkcija. Problem brzine rada bi se vjerojatno mogao djelomično izbjegnuti optimaliziranjem neuralne mreže, ali bi za ozbiljniji rad bilo uputno koristiti se nekim sofisticiranijim alatom.

Različiti tipovi satelitskih snimaka ovisno o tehnologiji daljinskog motrenja zasigurno imaju ključnu ulogu za klasifikaciju. U osnovi, najbitnija su dva parametra i to:

- prostorna razlučivost satelitske snimke koja utječe na minimalnu širinu i/ili površinu koju je moguće identificirati. U ovom je slučaju to 30 m, ali postoje i satelitske snimke s boljom razlučivošću;
- broj kanala i raspon njihovih spektara koji definiraju vektor elementa satelitske snimke

Odabirom odgovarajućeg tipa satelitske snimke uvelike se može olakšati njegova klasifikacija za pojedine potrebe, a o broju kanala i rasponu njihovih spektara ovisi o potrebne karakteristike i parametri neuralne mreže.

Na osnovi svega spomenutog može se zaključiti da je klasifikacija satelitske snimke s pomoću neuralne mreže dala sasvim zadovoljavajuće rezultate te opravdala načelni koncept.

S obzirom na to da postoje otvorene mogućnosti daljnjih unapređenja većine elemenata te unapređenja ukupnog koncepta, velika je vjerojatnost da bi se mogli dobiti još bolji i pouzdaniji rezultati te bi svakako bilo uputno nastaviti istraživanja na tom planu.

## IZVORI

[1] Žagar, Z.: *Ekspertni sustavi*, FGZ Zagreb, Zagreb, 1991.

[2] Anderson, D.; McNeill, G.: *Artificial Neural Networks Technology*, Utica, USA, 1992.

- [3] Pauše, Ž.: *Uvod u matematičku statistiku*, Školska knjiga, Zagreb, 1993.
- [4] Lillesand, T.M.; Kiefer, R.W.: *Remote sensing and Image Interpretation*, John Wiley & Sons, New York, USA, 1994.
- [5] Meijerink, A.: *Introduction to the Use of Geographic Information Systems for Practical Hydrology*, International Institute for Aerospace Survey and Earth Sciences, Enschede, Netherlands, 1994.
- [6] ESRI: *Using Avenue - Customization and Application Development for ArcView*, Environmental Systems Research Institute, Inc., Redlands, USA, 1997.
- [7] Japan International Cooperation Agency: *The Study for Water Pollution Reduction on the Sava River Basin in the Republic of Croatia*, Zagreb, 2001.