

UMJETNE NEURONSKE MREŽE U PROCJENI SASTOJINSKIH OBRASTA S CIKLICKIH SNIMAKA

ARTIFICIAL NEURAL NETWORKS IN THE ESTIMATION OF STAND
DENSITY FROM CYCLIC AERIAL PHOTOGRAPHS

Damir KLOBUČAR*, Renata PERNAR**

SAŽETAK: *Zbog svoje široke primjene, gotovo da se danas može reći da je ovo vrijeme prijelaza na tehnologiju umjetnih neuronskih mreža. Stoga je cilj ovog rada predstaviti tu tehnologiju i njezinu primjenu u daljinskim istraživanjima. U tu svrhu korišten je digitalni ortofoto izrađen iz crno-bijelih aeroftosnimaka, približnog mjerila 1:20 000.*

Istraživanjem je obuhvaćena gospodarska jedinica "Jamaričko brdo", šumarije Lipovljani.

Procjena sastojinskog obrasta provedena je primjenom višeslojnog perceptrona, kao najkorištenijeg modela umjetnih neuronskih mreža u daljinskim istraživanjima. Također je korištena samoorganizirajuća neuronska mreža sa svrhom kontrole utvrđenih obrasta u Osnovi gospodarenja, prema njihovoj raspodjeli u tri kategorije (normalan, manji od normalnog, slab).

Provedenim istraživanjem dobivena su dobra generalizacijska svojstva višeslojnog perceptrona u procjeni obrasta, kao i da se samoorganizirajuća neuronska mreža može primijeniti u kontroli i raspodjeli sastojinskih obrasta.

Kako se u šumarstvu svakodnevno provodi velik broj različitih mjeranja, upravo umjetne neuronske mreže predstavljaju model temeljen na teoriji učenja, kojim bi se značajnije moglo unaprijediti korištenje ovako velikog broja podataka, koji su se do sada rješavali isključivo statističkim metodama i metodama operacijskih istraživanja.

Ključne riječi: umjetne neuronske mreže, daljinska istraživanja, ciklicki snimke, obrast, tekstura.

1. UVOD – Introduction

Već gotovo dva desetljeća u istraživanju i proučavanju vegetacije dolazi do primjene naprednih tehnika poput umjetnih neuronskih mreža. Krajem 80-tih godina prošloga stoljeća u SAD i Kanadi počeli su prvi eksperimenti primjene neuronskih mreža u šumarstvu (Scr inzi i dr. 2000), koje se razvijaju kao alternativni pristup u modeliranju nelinearnih i kompleksnih pojava u šumarskoj znanosti (Gimblett i Ball 1995, Lek i dr. 1996, Peng i Wen 1999, Liu i dr. 2003).

U dosadašnjimm istraživanjima neuronske mreže primjenjivane su za:

- Klasifikaciju i kartiranje zemljišta
- Analizu prostornih podataka i GIS modeliranje
- Primjena neuronskih mreža u daljinskim istraživanjima,
- Integracija neuronskih mreža u GIS sa svrhom prostornog modeliranja
- Rast šume i dinamičko modeliranje
- Dinamiku biljnih bolesti, praćenje insekata i zaštiti od šumskih požara.

U daljinskim istraživanjima primjena umjetnih neuronskih mreža počinje ranih devedesetih godina XX stoljeća (Benediktsson i dr. 1990, Hepner i dr. 1990,

* Dr. sc. Damir Klobučar, dipl. ing. šum., UŠP Zagreb, V.

Nazora 7, 10 000 Zagreb, e-mail: damir.klobucar@hrsume.hr

** Izv. prof. dr. sc. Renata Pernar, dipl. ing. šum., Šumarski fakultet u Zagrebu, Svetosimunska 25, 10 000 Zagreb,
e-mail: rpernar@sumfak.hr

Civco 1993). Najčešće se koristi višeslojni perceptron (engl. multilayer feed – forward network – MLP) (Paola i Schowengerdt 1995, Atkinson i Tannall 1997, Kanellopoulos i Wilkinson 1997, Foody 2001), te znatno slabije drugi modeli kod neuronskih mreža s nadgledanim učenjem. Također se primjenjuju neuronske mreže s nenadgledanim učenjem, kao što je samoorganizirajuća neuronska mreža (engl. self – organizing map – SOM; Beamish 2001).

Istraživanja u području primjene daljinskih istraživanja u šumarstvu sa svrhom određivanja kvantitativnih i kvalitativnih parametara šume ukazala su na koristnost umjetnih neuronskih mreža (Ardö i dr. 1997, Skidmore i dr. 1997, Wang i Dong 1997, Moisen i Frescino 2002, Ingram i dr. 2005, Joshi i dr. 2006, Kuplich 2006, Verbeke i dr. 2006, Klobu-

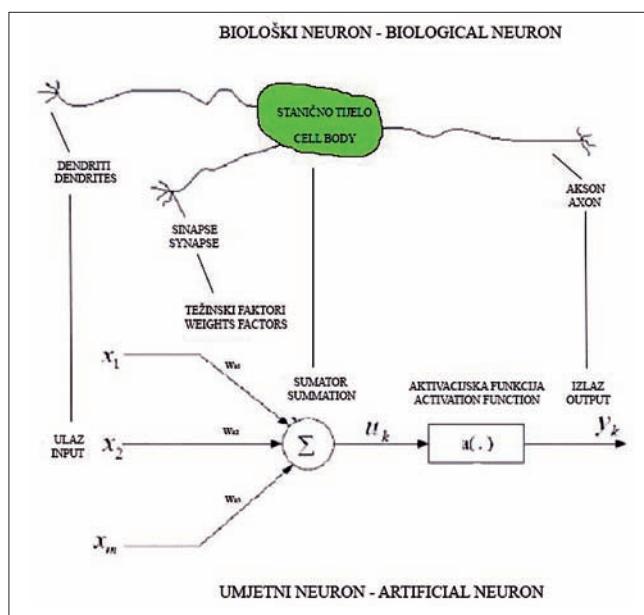
čar i dr. 2008) kao alternativnog pristupa klasičnim statističkim metodama.

Primjenom tehnike digitalne obrade sastojinskih scena u posljednjih desetak godina došlo je do razvoja novih metoda u procjeni sastojinskog obrasta (Bolduc i dr. 1996, Wulder i dr. 2000, St-Onge i Cavayas 1997, Franco - Lopez i dr. 2001, Hölmstrom 2002, Verbeke i dr. 2006).

Dosadašnjim istraživanjima (Klobučar 2003, Pernar i Klobučar 2003, Pernar i dr. 2003, Klobučar 2004, Klobučar i Pernar 2005, Klobučar 2008) ukazano je na mogućnosti primjene cikličkih snimaka u šumarstvu. Među značajnijim rezultatima svakako je utvrđena povezanost histograma prvoga i drugoga reda s kategorijama sastojinskih obrasta.

1.1. Umjetne neuronske mreže – *Artificial neural networks*

Umjetne neuronske mreže (engl. artificial neural networks – ANN) su metoda umjetne inteligencije (engl.



Slika 1. Odnos glavnih komponenti biološkog i umjetnog neurona
Figure 1 Relationship between the main components of a biological and artificial neuron

1.2. Podjela umjetnih neuronskih mreža – *Classification of artificial neural networks*

Gradi, odnosno arhitekturu ili topologiju neuronske mreže, možemo razlikovati s obzirom na način povezivanja neurona u mrežu. Postoji velik broj kriterija za razlikovanje arhitektura neuronskih mreža. Ovdje će se opisati samo osnovni čimbenici podjele: broj slojeva, tip učenja, smjer putovanja signala kroz mrežu, tip veze između neurona, ulazne i prijenosne (aktivacijske) funkcije.

Neuroni povezani u mrežu organizirani su u slojeve. Svaka mreža ima neurone koji služe za prihvatanje ulaznih

artificial intelligence) strukturirane prema ljudskom mozgu. Pripadaju sekvencijalnim metodama modeliranja i predstavljaju jednu od najmodernijih metoda ne-linearnog programiranja. Za razumijevanje modela umjetnih neuronskih mreža važno je osnovno poznavanje strukture bioloških neurona.

Biološki i umjetni neuron imaju slične temeljne procese, te su usporedivi (Slika 1).

Tijelo biološkog neurona zamjenjuje se sumatom, a ulogu dendrita preuzimaju ulazi u sumator. Izlaz sumatora je akson umjetnog neurona, a uloga praga osjetljivosti bioloških neurona preslikava se na tzv. aktivacijske funkcije. Funkcije sinaptičke veze biološkog neurona s njegovom okolinom preslikavaju se na težinske faktore, preko kojih se i ostvaruje veza umjetnog neurona s njegovom okolinom. Izlaz iz drugih neurona i/ili okruženja promatranog neurona, koji se upućuju promatranom neuronom, množe se težinskim faktorima i dovode do sumatora. U sumatoru se tako dobiveni produkti sumiraju, a njihova suma se dovodi na ulaz aktivacijske funkcije, koja će na svom izlazu dati izlaz neurona (Novaković i dr. 1998).

1.2. Podjela umjetnih neuronskih mreža – *Classification of artificial neural networks*

vrijednosti i čine ulazni sloj neurona, te neurone koji daju odgovor mreže i čine izlazni sloj neurona. Svi ostali neuroni koji se nalaze između tih dvaju slojeva čine skriveni sloj neurona (Dalbelo Bašić 2004). Tim slijedom neuronske mreže mogu biti: jednoslojne i višeslojne. Jednoslojna mreža sastoji se od jednog sloja neurona (izlaznog sloja), dok se ulazni sloj ne broji, jer u njemu nema procesiranja. Višeslojne mreže imaju osim ulaznog i izlaznog sloja i jedan ili više skrivenih slojeva neurona (Lončarić 2003).

Glavni zadatak mreže je da nauči model okoline (svijeta) u kojoj će raditi i da održava model dovoljno točnim da bi se mogli postići željeni ciljevi danog sustava. Neuronska mreža uči o okolini kroz iterativni proces podešavanja sinaptičkih težina i pragova. Učenje je proces kojim se slobodni parametri neuronske mreže adaptiraju kroz kontinuirani proces stimulacije od okoline u kojoj se mreža nalazi (Haykin 1999). Skup pravila za rješenje problema učenja zove se algoritam učenja (učenje korekcijom pogreške, Hebbovo učenje, kompetitivno učenje, Boltzmanovo učenje, Thorndikeovo učenje). Algoritam učenja određuje način izračunavanja promjena sinaptičke težine u trenutku n , dok paradigmе učenja (učenje pod nadzorom, učenje podrškom, učenje bez nadzora) određuju odnos neuronske mreže prema okolini (Lončarić 2003).

Kod učenja pod nadzorom (engl. supervised learning) podaci za treniranje sastoje se od primjera s poznatim ulazno-izlaznim vrijednostima. Mreža stvara izlaz, računa pogrešku (razlika između željenog i dobivenog odziva za ulazni vektor) i prilagođava težine s obzirom na pogrešku. Proces se iterativno ponavlja sve dok mreža ne nauči imitirati učitelja.

Dakle, učenje pod nadzorom pretpostavlja postojanje ciljne vrijednosti za svaku ulaznu vrijednost. U nekim situacijama nije moguće osigurati takvu informaciju, već samo informaciju koja govori je li izlazna vrijednost poželjna ili nije. Ovaj tip učenja naziva se učenje podrškom (engl. reinforcement). Kod ovog učenja ne postoji učitelj koji određuje kolika je pogreška za određeni ulazno-izlazni par, nego učitelj kaže koliko je određeni korak u učenju dobar (daje ocjenu ili podršku).

Učenje podrškom rješava problem učenja pod nadzorom, tj. da bez učitelja mreža ne može naučiti nove

strategije, koje nisu pokrivene primjerima koji su korišteni za učenje.

Kod učenja bez nadzora (engl. unsupervised learning) nisu poznate izlazne vrijednosti. Ulazi su raspoloživi mreži, a težine se ne prilagođavaju na osnovi stvarnih vrijednosti izlaza. Ovdje se neuronska mreža sama organizira, pa se mreže učene ovom metodom nazivaju samoorganizirajuće neuronske mreže.

Ako su slojevi neurona povezani na način da signali putuju u jednom smjeru od ulaza prema izlazu mreže, takav tip mreže se naziva unaprijedna neuronska mreža. Ako postoji bar jedna povratna veza mreža se naziva povratnom.

Prema tipu, veze između neurona mogu se ostvarivati između dva sloja (inter-slojna) i između neurona u jednom sloju (intra-slojna).

Kada neki neuron prima ulaz iz prethodnog sloja, vrijednost njegovog ulaza računa se prema ulaznoj funkciji, obično zvanoj "sumacijska" funkcija.

Aktivacijske ili transfer funkcije, koriste se za smanjivanje broja iteracija. Uvode nelinearnost u neuronske mreže i unapređuju njezino provođenje (Cetin i dr. 2004). Postoji veći broj aktivacijskih funkcija, a u radu su korištene: linearna, logaritamsko-sigmoidna, hiperboličko-tangentno-sigmoidna i triangularna.

Slijedom navedenog, neuronske mreže mogu se podijeliti u četiri glavne vrste: jednoslojne mreže bez povratnih veza (*single-layer feedforward networks*), višeslojne mreže bez povratnih veza (*multi-layer feedforward networks*), mreže s povratnim vezama (*recurrent networks*), ljestvičaste mreže (*lattice structures*) (Lončarić 2003).

1.3. Prednosti i nedostaci neuronskih mrež *Advantages and disadvantages of neural networks*

Umjetne neuronske mreže točnije su od ostalih statističkih tehniki, osobito kada je problem ili zadatak slabo definiran ili nerazumljiv, te ne zahtijevaju a priori znanje o određenom procesu. Neuronska mreža može razviti vlastiti plan temeljen na odnosu između varijabli, a to se posebno odnosi na nelinearne sisteme, gdje se klasične statističke tehnike ili matematički modeli ne mogu definirati. Sposobnost mreže da uči složene odnose i mogućnost uključivanja kvalitativnih i kvantitativnih podataka, rezultirao je da je postupak neuronske mreže vrlo fleksibilan i snažan alat (Peng i Wen 1999, Liu i dr. 2003). Jednom trenirane mreže mogu biti korištene u analizi novih uvjeta i davanju rješenja.

Kao eventualne nedostatke neuronskih mrež mogu se navesti teškoće u njihovom korištenju, a odnose se na potrebno vrijeme treniranja i determinaciju djelotvorne mrežne strukture, nasuprot jednostavnijim metodama

(Kavzoglu i Mather 1999). Neuronske mreže ne nude kao konačni model podataka razumljiv odnos važnih varijabli. Naime, odnosi između varijabli skriveni su u mrežnoj strukturi i težinskim faktorima veza neuronske mreže. Prema (Dalbelo Bašić 2004) neuronska mreža ne može davati suvisle odgovore izvan raspona vrijednosti primjera iz kojih je učila, a postupak generalizacije naučenih primjera uspješan je samo kod relativno "neprekidnih" pojava. Uspješno učenje zahtijeva veliki broj podataka, a to ponekad može biti problem.

2. CILJ I PODRUČJE ISTRAŽIVANJA – Goal and area of research

U ovom radu istražuju se mogućnosti procjene i raspodjele sastojinskih obrasta metodom umjetnih neuronskih mreža, korištenjem određenih teksturalnih značajki histograma prvoga i drugoga reda na digitalnom ortofotu izrađenom iz crno-bijelih aerofotosnimaka, približnog mjerila 1:20 000. Uz navedeno, cilj

rada je i prikupljanje podataka s prihvatljivom točnošću, koje će zahtijevati manja materijalna ulaganja. Istraživanje je provedeno na području G. J. "Jamaričko brdo", šumarije Lipovljani. Cikličko snimanje provedeno je 2000. godine.

3. METODE RADA – Work methods

Da bi se odredile teksturalne značajke histograma prvoga i drugoga reda isječen je uzorak s digitalnog ortofota za 80 sastojinskih scena (odsjeka/odjela) u uređajnim razredima hrasta lužnjaka, hrasta kitnjaka i obične bukve, IV (najučestaliji), V i VI dobnog razreda.

U analizi tekstura uobičajeni postupak odnosi se na statističke osobine intenziteta histograma prvog reda. MATLAB funkcijom *statxture* (Gonzales i Woods 2004) izračunato je šest statističkih vrijednosti: aritmetička sredina, standardna devijacija, smoothnes, treći moment, jednoličnost (*uniformity*) i entropija.

MATLAB funkcija *imtexfeat* (Petkov 2004) korištena je za određivanje značajki histograma drugog reda. U ovom slučaju blok je predstavljao uzorak sastojinske scene, a vektorski pomak je bio [Dx (1) Dy (1)], te je izračunato pet teksturalnih značajki: apsolutna vrijednost razlike, inercija, kovarianca, entropija i energija.

Opisanim postupkom ukupno je ekstrahirano jedanaest značajki tekture za svaku sastojinsku scenu (odsjek/odjel), čime je formiran set podataka (vektora) za ulaz u model neuronske mreže.

3.1. Izrada optimalne arhitekture višeslojnog perceptronra *Construction of an Optimal Structure of Multi Layer Perceptron*

Postupak izrade optimalne arhitekture neuronske mreže proveden je poslije ekstrakcije teksturalnih značajki sastojinske scene za 80 odsjeka/odjela. U rješavanju problema procjenjivanja sastojinskog obrasta primijenjen je višeslojni perceptron. Višeslojni perceptron je neuronska mreža bez povratnih veza, gdje se učenje pod nadzorom odvija pomoću algoritma s povratnom propagacijom pogreške (*error back-propagation algorithm*).

U cilju unapređenja generalizacije korištena je metoda ranijeg zaustavljanja (engl. early stopping). Generalizacija je svojstvo mreže kada mreža "dobro" radi i s vektorima koji nisu sadržani u skupu primjera s kojima je mreža trenirala. Postoji veći broj varijacija algoritma s povratnom propagacijom pogreške, s tim da kod metode ranijeg zaustavljanja nije shodno koristiti algoritam koji previše brzo konvergira (Xiangcheng i dr. 2005, Demuth i dr. 2006), te su primjenjena dva algoritma: *resilient back-propagation* i *scaled conjugate gradient algorithm*.

Izlazne vrijednosti mogu biti predstavljene i kao broj stabala, temeljnica ili volumen po hektaru ili kao neke druge kvantitativne i kvalitativne vrijednosti sastojine. Zbog slabijih spektralnih obilježja primjenjenih snimaka, kao i činjenica da se njihovo pridobivanje provodi u periodu koji je nepovoljan sa stajališta šumarske struke (doba godine kada je zemljište najmanje prekriveno raslinjem), kao izlazna vrijednost upotrebljen je sastojinski obrast.

Za testiranje razlike u vrijednostima sastojinskih obrasta između podataka Osnove gospodarenja (važnost Osnove gospodarenja 2002.–2011. godine) i optimalnog modela umjetne neuronske mreže primjenjena je analiza varijance ponovljenih mjerena.

U izradi arhitekture umjetnih neuronskih mreža korišten je programski paket MATLAB 6.5 Demuth i dr. 2006), a za statističku analizu program STATISTICA 7.1.

U primjeni metode ranijeg zaustavljanja zapravo se radi o statističkoj metodi kros – validacije (*cross-validation*) u kojoj se cijelokupni skup podataka dijeli na tri seta: za treniranje, validaciju i testiranje. Od cijelokupnog skupa podataka setu za treniranje dodijeljeno je 50 %, odnosno 40 odsjeka/odjela, dok su na preostala dva seta podaci podijeljeni u jednakom omjeru: 25 % (20 odsjeka/odjela) na set za validaciju i 25 % (20 odsjeka/odjela) na set za testiranje.

Prije samog treniranja neuronske mreže provedeno je preprocesiranje podataka, te su u tom smislu korišteći MATLAB funkcije izvršene dvije operacije: normalizacija ulazno-izlanih vrijednosti i analiza glavnih komponenti ulaznih vrijednosti.

Analizom glavnih komponenti reducirana je dimenzija ulaznih vektora, te su u ovom slučaju eliminirane one komponente koje sudjeluju s manje od 1 % (zadana vrijednost) u totalnoj varijanci ulaznih podataka, čime je broj ekstrahiranih značajki tekture s 11 sveden na 7. Nakon izvršenog treniranja, generalizirani i normalizirani podaci konvertirati su u standardne jedinice.

Ukupno je trenirano sedam modela algoritma s povratnom propagacijom pogreške s jednim ili dva skrivena sloja, u kojima je bio različit broj skrivenih neurona. Također su u skrivenim i izlaznim slojevima

3.2. Priprema podataka za raspodjelu sastojinskih obrasta primjenom samoorganizirajuće neuronske mreže

Preparation of data for classification of stand densities by using a self-organizing neural network

Sa svrhom kontrole Osnovom gospodarenja utvrđenih obrasta prema njihovoj raspodjeli u tri kategorije: normalan, manji od normalnog, slab (NN 111/06), korištena je samoorganizirajuća neuronska mreža.

U cilju istraživanja primjenjivosti ove neuronske mreže, 80 odsjeka/odjela, podijeljeno je u dva seta: set za treniranje i set za testiranje (set za validaciju i set za testiranje iz prethodnog primjera). Svaki set je sadržavao 40 odsjeka/odjela.

Kao i kod višeslojnog perceptronu prije treniranja neuronske mreže izvršeno je preprocesiranje podataka, te je provedena normalizacija i analiza glavnih komponenti ulaznih vrijednosti seta za treniranje. Analizom glavnih komponenti eliminirane su komponente koje sudjeluju s manje od 1 % u totalnoj varijanci ulaznih podataka, te je broj ulaznih značajke teksture s 11 smanjen na 6.

Ukupno su trenirane 34 mrežne arhitekture (dimenzije sloja). Dimenzija sloja predstavlja broj zadanih neurona (broj klastera), odnosno topologiju neuronske mreže. Na temelju ulazne vrijednosti (značajke teksture),

primjenjene različite aktivacijske funkcije (hiperboličko-tangentno-sigmoidna, linearna, logaritamsko-sigmoidna i triangularna).

4. REZULTATI ISTRAŽIVANJA I RASPRAVA – Research results and discussion

4.1. Optimalna arhitektura višeslojnog perceptronu

Optimal architecture of a multilayer perceptron

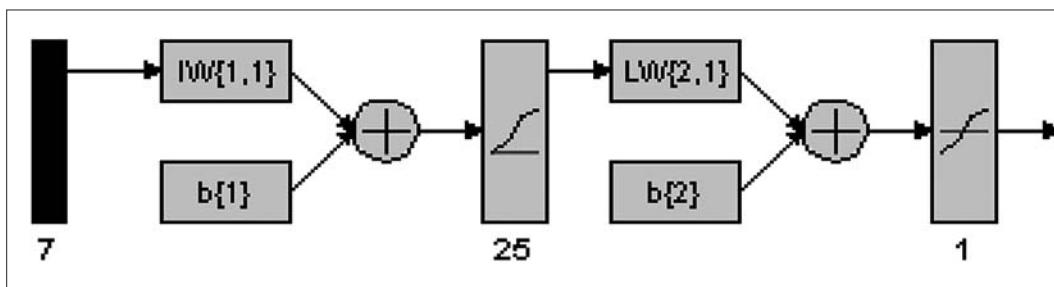
U odabiru najprihvatljivije arhitekture korištena je najmanja vrijednost srednje kvadratne pogreške seta za testiranje. Arhitektura s najmanjom vrijednosti ciljne (troškovne) funkcije kod metode ranijeg zaustavljanja

svakom odsjeku/odjelu dodijeljen je određeni klaster. Budući da je u primjeni ovog modela neuronske mreže za cilj grupiranje odsjeka/odjela u tri kategorije obrasta, arhitektura s minimalnim brojem sadržavala je 3 neurona, odnosno 3 klastera, dok je maksimalni broj neurona, odnosno klastera u arhitekturama [2 10] i [10 2] bio 20. Dakle, odsjecima/odjelima unutar pojedine kategorije obrasta dodijeljen je veći broj klastera, što se uglavnom odnosilo na sastojine normalnog obrasta, koje su najzastupljenije.

Nakon provedenih treniranja analizirani su podaci s ciljem utvrđivanja koje su arhitekture raspoznale tri kategorije obrasta, kao i koji klasteri definiraju određenu kategoriju obrasta. To su klasteri s najvećom učestalosću u pojedinoj kategoriji obrasta.

Slijedom navedenog, utvrđen je po arhitekturama broj točno dodijeljenih klastera. Nakon ove obrade podataka provedena je generalizacija navedenih arhitektura na novom skupu podataka (set za testiranje), koji se također sastoji od 40 odsjeka/odjela G. J "Jamaričko Brdo".

utvrđena je kod *scaled conjugate gradient* algoritma s 25 neurona u skrivenom sloju i logaritamsko-sigmoidnom funkcijom na svom izlazu, te hiperboličko-tangentno-sigmoidnom funkcijom u izlaznom sloju (Slika 2).



Slika 2. Arhitektura neuronske mreža 7-25-1
Figure 2 Neural network architecture 7-25-1

4.2. Rezultati procjene sastojinskih obrasta – Results of stand density estimation

Kod seta za testiranje (20 odsjeka/odjela) uspoređene su vrijednosti obrasta dobivene optimalnim modelom s vrijednostima obrasta koje su utvrđene Osnovom

gospodarenja (Tablica 1). Izlazne vrijednosti obrasta za ovaj set nisu bile predviđene mreži tijekom učenja, te su na ovom setu ispitana generalizacijska svojstva mreže.

Tablica 1. Rezultati procjene sastojinskih obrasta

Table 1 Results of stand density estimation

Odjel Compart	Odsjek Subcompart	Površina (ha) Area (ha)	Obrast Density	Procjenjeni obrast Estimated density	Razlika Difference
13	b	12.05	0.94	0.84	0.10
17	a	20.17	0.96	0.89	0.07
21	a	27.00	1.01	0.88	0.13
23	b	13.81	0.85	0.90	-0.05
24	b	4.26	0.81	0.70	0.11
28	a	13.19	0.97	0.87	0.10
31	a	16.27	1.01	0.86	0.15
34	a	14.74	0.96	0.93	0.03
38	a	13.73	1.04	0.70	0.34
42	a	21.05	1.02	0.91	0.11
50	a	10.80	0.95	0.74	0.21
58	a	30.24	0.84	0.94	-0.10
62	a	19.06	0.85	0.80	0.05
66	a	20.49	0.84	0.98	-0.14
68	b	18.79	0.83	0.87	-0.04
45	b	4.62	0.51	0.67	-0.16
51	a	26.85	0.76	0.86	-0.10
61	b	1.81	0.64	0.68	-0.04
70	a	25.66	0.78	0.85	-0.07
50	c	0.92	0.31	0.85	-0.54

Najveće odstupanje odnosi se na odsjek (50c – 0,92 ha) sa slabim obrastom. Smatra se da je glavni razlog odstupanju mala površina ovog odsjeka, čime se potvrđuju i pretvodna istraživanja (H y p p ä i H y p p ä 2001, Kušan i Pernar 2001, Klobučar 2004) u kojima je utvrđeno da odsjeci malih površina nisu najpogodniji za daljinska istraživanja.

Tablica 2. Rezultati analize varijance ponovljenih mjerena

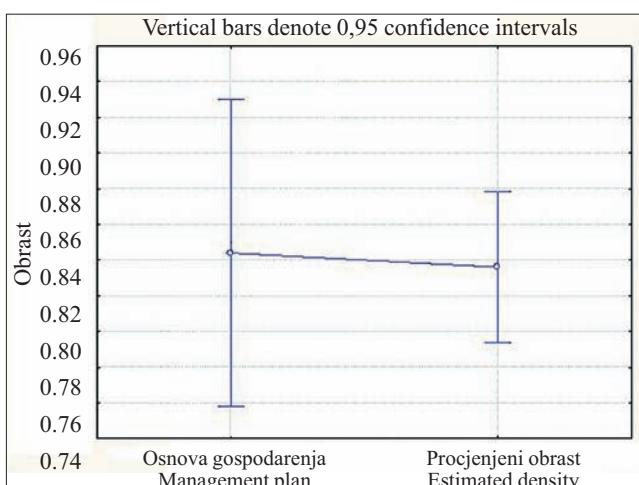
Table 2 Results of repeated measures analysis of variance

G. J. "Jamaričko brdo" – M. U. "Jamaričko brdo"					
	SS	Df	MS	F	p
Intercept	28.22508	1	28.22508	1097.681	0.000000
Error	0.48855	19	0.02571		
Model	0.00063	1	0.00063	0.039	0.844770
Error	0.30618	19	0.01611		

Provedena analiza varijanci ponovljenih mjerena (Tablica 2) ukazuje da ne postoji statistički značajna razlika između vrijednosti obrasta utvrđenih Osnovom gospodarenja i optimalnog modela.

Iz grafičkih podataka (Slika 3) uočljivo je da podaci Osnove gospodarenja imaju nešto veći raspon vrijednosti, ali ta razlika nije značajna. Također, dobiveni rezultati potvrđuju da su obrasti za gospodarsku jedinicu dobro utvrđeni, te da optimalni model neuronske mreže ima dobra generalizacijska svojstva.

Razlozi odstupanja procjene nalaze se u nekoliko objektivnih činjenica:



Slika 3. Aritmetičke sredine i 95 % intervali pouzdanosti obrasta

Figure 3 Arithmetic means and 95 % reliability intervals of density

- 80 odsjeka/odjela G. J. "Jamaričko Brdo" na kojima je provedena metoda ranijeg zaustavljanja predstavlja relativno mali skup podataka; utjecaj metodnih pogrešaka u uređajnoj inventuri (Levaković 1919, Levaković 1923, Klobučar 2002); relativno dugo razdoblje terestičke izmjere; nedostaci neuronskih mreža; vremenski razmak između utvrđivanja obrasta Osnovom gospodarenja i aerosnimanja. Naime, u području daljinskih istraživanja, često puta teško je raspolažati aero i satelitskim scenama, odnosno terestičkim podacima, koji su priključeni u istom razdoblju (Food i Curran 1994, Ingram i dr. 2005).

4.3. Rezultati raspodjele sastojinskih obrasta – *Results of stand density distribution*

Od ukupno 34 arhitektura koje su korištene u postupku treniranja, raspoznavanje tri kategorije obrasta utvrđeno je kod dvadeset arhitektura. Navedenih dvadeset arhitektura koje su raspoznale tri kategorije obrasta simulirane su na značajkama seta za testiranje (Tablica 3).

Iz tablice je uočljivo da je najmanji, odnosno najveći broj netočno dodijeljenih klastera pet, odnosno jedanaest (2–9, 17). Pet netočno dodijeljenih klastera odnosi se na arhitekturu 8–2, koja je i pripadala grupi od šest najboljih arhitektura u fazi treniranja neuronske mreže. Dakle, za ovu arhitekturu 87,50% točno je klasificiranih odsjeka/odjela. Ostale arhitekture iz ove grupe imale su šest (3–4, 6–3), sedam (4–3, 4–5) i devet (2–10) netočno dodijeljenih klastera. Za navedene dvije najslabije arhitekture 72,50 % točno je klasificiranih odsjeka/odjela.

Tablica 3. Broj točno dodijeljenih klastera (kategorija obrasta) seta za testiranje
Table 3 Number of accurately assigned clusters (density categories) the testing set

Broj točno dodijeljenih klastera Number of accurately assigned clusters	Arhitektura Architecture	n
35 (87,50 %)	8-2	1
34 (85,00 %)	3-4, 6-3	2
33 (82,50 %)	2-6, 4-3, 4-5, 5-3	4
32 (80,00 %)	4-4	1
31 (77,50 %)	2-7, 2-10, 3-3, 3 -6, 7-2	5
30 (75,00 %)	2-5, 5-4, 6-2, 13, 19	5
29 (72,50 %)	2-9, 17	2

Netočno dodijeljeni klasteri uglavnom se odnose na odsjeke čiji se obrasti nalaze u rasponu od 0,50–0,80 i to su pretežito vrijednosti koje su bliže normalnom obrastu. U ovoj kategoriji kod seta za testiranje svi odjaci (8) imaju vrijednost od 0,70–0,77, što je zasigurno otežavalo identifikaciju ove kategorije.

4.4. Rasprava – *Discussion*

Primjenjeni postupak procjene sastojinskih obrasta metodama daljinskih istraživanja uz pomoć umjetnih neuronskih mreža svoju svrsishodnost u praksi svakako ima u pripremnim uredskim radovima za izradu Osnova gospodarenja, procjeni i kontroli uređajnom inventurom utvrđenih sastojinskih obrasta, kao i u procjeni volumena i stanja sastojina.

U kontroli teretičke izmjere primjena višeslojnog perceptronu uz prikazani način, uspješno se može kombinirati sa samoorganizirajućim neuronskim mrežama.

Rezultati procjene obrasta primjenom umjetnih neuronskih mreža, mogu se dopuniti izradom histograma prvoga i drugoga reda sastojinskih scena, kao i vizualnom interpretacijom (procjenom).

U prethodnim istraživanjima (Pernar i Klobučar 2003, Pernar i dr. 2003, Klobučar 2004, Klobučar i Pernar 2005, Klobučar 2008) na istim snimkama postignuti su primjereni rezultati u procjeni stanja sastojina, kao i u procjeni volumena sastojina, s tim da je obrast korišten kao ulazni parametar. Primjenjenim postupkom postiže se prihvatljiva točnost i visoki stupanj automatizma u procjeni obrasta, kojim se uklanjanju subjektivnosti klasičnih metoda daljinskih istraživanja, te smanjuju finansijska ulaganja.

Nakon izrade optimalne arhitekture neuronske mreže, procjenjivanje sastojinskih parametara (u ovom slučaju sastojinski obrast) zahtijeva samo ekstrakciju teksturalnih značajki sastojinske scene i njihovu simulaciju putem istrenirane neuronske mreže, što je uredski posao koji se odradi u vrlo kratkom razdoblju. Upravo brzina postupka, zadovoljavajuća točnost uz

neusporedivo manje troškove u odnosu na terestičku izmjjeru primjenjenom postupku daje veliku prednost.

Kako se u šumarstvu svakodnevno provodi velik broj različitih mjeranja, upravo umjetne neuronske mreže predstavljaju model temeljen na teoriji učenja, kojim bi se značajnije moglo unaprijediti korištenje ovako velikog broja podataka, koji su se do sada rješavali isključivo statističkim metodama i metodama operacijskih istraživanja.

Ovim istraživanjima potvrđene su prednosti (nije potrebno poznavati model podataka, primjena u analizi novih uvjeta, tolerantnost na nesavršenost podataka) i nedostaci (determinacija optimalne arhitekture, nemogućnost procjenjivanja izvan raspona vrijednosti podataka za učenje) umjetnih neuronskih mreža. U svakom slučaju prednosti umjetnih neuronskih mreža nadilaze njihove nedostatke.

No, uz mnogobrojne prednosti, umjetne neuronske mreže neće u potpunosti zamjeniti klasične statističke tehnike. Umjesto toga dualni pristup i integracija ovih dviju tehnika u donošenju odluka biti će vrlo korisna za gospodarenje šumskim resursima u 21. stoljeću (Peng i Wen, 1999).

Naime, danas one imaju široku primjenu, te se može reći da je ovo vrijeme prijelaza na tehnologiju umjetnih neuronskih mreža, pa je stoga korisno započeti nihovu šиру primjenu u šumarstvu RH.

5. ZAKLJUČCI – Conclusions

Istraživanje procjene i raspodjele sastojinskih obrasta postupkom umjetne neuronske mreže provedeno je na primjeru gospodarske jedinice "Jamaričko brdo", šumarije Lipovljani. Na osnovi provedenih istraživanja i dobivenih rezultata izvedeni su sljedeći zaključci:

- U šumarstvu RH, svršishodno primjenjivanje potvrđenih vrijednosti daljinskih istraživanja u praćenju stanja i inventarizaciji šumskega resursa zahtijeva razvijen sustav periodičnog snimanja ili pridobivanja scena šumske površine
- Višeslojni perceptron ima dobra generalizacijska svojstva u procjeni sastojinskih obrasta metodama

6. LITERATURA – References

- Atkinson, P. M., A. R. L. Tatnall, 1997: Neural networks in remote sensing. International Journal of Remote Sensing, 18: 699–709.
- Ardö, J., P. Pilesjo, A. Skidmore, 1997: Neural networks, multitemporal Landsat Thematic Mapper data and topographic data to classify forest damage in the Czech Republic. Canadian Journal of Remote Sensing, 23, 217–219.
- Beamish, D. 2001: A Review of Neural Networks in Remote Sensing, 1–45.
- Benediktsson, J. A., P. H. Swain, O. K. Evsøy, 1990: Neural network approach versus statistical methods in classification of multi-source remote sensing data. IEEE Transactions on Geoscience and Remote Sensing, 28(4), 540–551.
- Bolduc, P., K. Lowell, G. Edwards, 1999: Automated estimation of localized forest volumes from large-scale aerial photographs and ancillary cartographic information in a boreal forest. International Journal of Remote Sensing 20(18), pp. 3611–3624.
- Cetin, M., T. Kavzoglu, N. Musaoglu, 2004: Classification of multi-spectral, multi-temporal and multi-sensor images using principal components analysis and artificial neural networks: Beykoz case.
- Civco, D. L. 1993: Artificial neural networks for land cover classification and mapping. International Journal of Geographical Information Systems 7: 173–186.
- Dalbelo Bašić, B. 2004: Sustavi koje uče. Knjiga "Informacijska tehnologija u poslovanju", 191–209, Zagreb.
- Demuth, H., M. Beale, M. Hagan, 2006: Neural Network Toolbox for Use with Matlab® User's Guide. Version 5. The Mathworks Inc., Natick, MA.
- Foody, G. M., P. J. Curran, 1994: Estimation of tropical forest extent and regenerative stage using remotely sensed data. Journal of Biogeography, 21, 223–244.
- Foody, G.M. 2001: Thematic mapping from remotely sensed data with neural networks: MLP, RBF and PNN based approaches, Journal of Geographical Systems 3: pp. 217–232.
- Franco-Lopez, H., A. R. Ek, M. E. Bauer, 2001: Estimation and mapping of forest stand density, volume, and cover type using the k-nearest neighbors method. Remote Sensing of Environment, 77, 251–274.
- Gimblett, R. H., G. L. Ball, 1995. Neural network architectures for monitoring and simulating changes in forest resources management. AI Applications 9: 103–123.
- Gonzales, R. C., R. E. Woods, S. L. Eddins, 2004: Digital Image Processing using MATLAB.
- Haykin, S. 1999: Neural Networks: A Comprehensive Foundation. Prentice Hall, New Jersey.
- Hepner, G. F., T. Logan, N. Ritter, N. Bryant, 1990: Artificial neural network classification using a minimal training set: Comparison to conventional supervised classification. Photogrammetric Engineering and Remote Sensing 56: 469–473.
- Holmström, H. 2002: Estimation of single tree characteristics using the kNN method and plotwise aerial photograph interpretations. Forest Ecology and Management, Volume 167, Issues 1–3, 303–314.
- Hyppä, H. J., J. M. Hyppä, 2001: Effects of Stand Size on the Accuracy of Remote Sensing – Based Forest Inventory. IEEE Transactions on Geoscience and Remote Sensing, Vol. 39, No. 12, 2613–2621.

daljinskih istraživanja s crno-bijelih cikličkih aerofotostimaka

- Samoorganizirajuća neuronska mreža može se primjeniti u kontroli raspodjele sastojinskih obrasta s cikličkih aerofotostimaka
- Ovim istraživanjem naznačena je jedna od velikog broja mogućnosti primjene umjetnih neuronskih mreža u šumarskoj znanstvenoj i operativnoj djelatnosti. Stoga, istraživanja i primjenu treba nastaviti i na drugim područjima (iskorištavanje, zaštita, ekologija i dr.) kako bi se racionalizirali radovi u šumarstvu.

- Ingram, J. C., T. P. Dawson, R. J. Whittaker, 2005: Mapping tropical forest structure in southeastern Madagascar using remote sensing and artificial neural networks. *Remote Sensing of Environment* 94, 491–507.
- Joshi, C., J. De Leeuw, A. K. Skidmore, I. C. van Duren, H. Oosten, 2006: Remotely sensed estimation of forest canopy density: A comparison of the performance of four methods. *International Journal of Applied Earth Observation and Geoinformation* 8, 84–95.
- Kanellopoulos, I., G. G. Wilkinson, 1997: Strategies and best practise for neural network image classification. *International Journal of Remote Sensing* 18, 711–725.
- Kavzoglu, T., P. M. Mather, 1999: Pruning artificial neural networks: an example using land cover classification of multisensor images. *International Journal of Remote Sensing*, 20 (14), pp. 2787–2803.
- Klobučar, D. 2002: Mogućnost primjene aerofotsnimaka iz cikličkog snimanja Republike Hrvatske u uređivanju šuma. Magistarski rad, 176, Šumarski fakultet Zagreb.
- Klobučar, D. 2003: Ocjena točnosti geokodiranja Osnovne državne karte i digitalnog ortofota. Šum. list 9–10, 457–465, Zagreb.
- Klobučar, D. 2004: Izlučivanje sastojina prema sklopu na digitalnom ortofotu i usporedba sa teretičkim izlučivanjem. Rad. Šumar. inst. 39 (2): 223–230, Jastrebarsko.
- Klobučar, D., R. Pernar, 2005: Picture histogram and interpretation of digital orthophotos in forest management. Proceedings of the 4th international symposium on image and signal processing and analysis: 395–401, Zagreb.
- Klobučar, D. 2008: Primjena histograma drugoga reda reda u procjeni relativnog sastojinskog obrasta. Šum. list 9–10, 419–429, Zagreb.
- Klobučar, D., R. Pernar, S. Lončarić, M. Sušić, 2008: Artificial neural networks in the assessment of stand parameters from an IKONOS satellite image. *Croatia Journal of Forest Engineering*. Vol. 29, Issue 2, 201–211, Zagreb.
- Kuplich, T. M. 2006: Classifying regenerating forest stages in Amazonia using remotely sensed images and a neural network. *Forest Ecology and Management* 234, 1–9.
- Kušan, V., R. Pernar, 2001: Primjena satelitskih snimaka za procjenu stanja sastojina. Znanstvena knjiga "Znanost u potrajinom gospodarenju Hrvatskim šumama", 429–434, Zagreb.
- Lek, S., M. Delacoste, P. Baran, I. Dimopoulou, J. Lauques, S. Aulagnier, 1996: Application of neural networks to modelling nonlinear relationships in ecology. *Ecol. Modell.* 90: 39–52.
- Levaković, A. 1919: Zaokruživanje promjera kod klupovanja sastojine. Šum. list 43 (11–12): 343–350, Zagreb.
- Levaković, A. 1923: Još nešto o veličini dopustivog zaokruženja u očitavanju promjera prigodom klupovanja sastojina. Šum. list 47 (4): 199–203, Zagreb.
- Liu, C., L. Zhang, C. J. Davis, D. S. Solomon, T. B. Brann, D. S. Caldwell, 2003: Comparison Of Neural Networks and Statistical Methods in Classification of Ecological Habitats Using FIA Data. *Forest Science* 49 (4) 2003.
- Lončarić, S. 2003: Predavanja. [ttp://ipg.zesoi.fer.hr](http://ipg.zesoi.fer.hr)
- Moisen, G. G., T. S. Frescino, 2002: Comparing five modelling techniques for predicting forest characteristics. *Ecological Modelling* 157 (2002) 209–225.
- Novaković, B., D. Majetić, M. Široki, 1998: Umjetne neuronske mreže. Fakultet strojarstva i brodogradnje, 240 pp, Zagreb.
- Paola, J. D., R. A. Schowengerdt, 1995: A review and analysis of backpropagation neural networks for classification of remote – sensed multi spectral imagery. *International Journal of Remote Sensing*, 16, 3033–3058.
- Peng, C., X. Wen, 1999: Recent Application of Artificial Neural Networks in Forest Resource Management: An Overview. In: Environmental Decision Support Systems and Artificial Intelligence, Ulises Corté and Miquel Srñchez – Marrc, Cochairs (eds.). pp. 15–22. Tech. Rep. WS-99-07, AAAI Press, Menlo Park, California.
- Pernar, R., D. Klobučar, 2003: Estimating stand density and condition with use of picture histograms and visual interpretation of digital orthophotos. *Glas. šum. pokuse* 40: 81–111, Zagreb.
- Pernar, R., D. Klobučar, V. Kušan, 2003: The application of aerial photographs from cyclic recordings in the Republic of Croatia to forest management. *Glas. šum. pokuse* 40: 113–168, Zagreb.
- Petković, T. 2004: Zavod za elektroničke sustave i obradu informacija. Fakultet elektrotehnike i računarstva Sveučilišta u Zagrebu. Upute za laboratorijske vježbe iz digitalne obrade slike, 44, 57–59.
- Scrinzi, G., A. Floris, M. Picci, 2000: Artificial neural networks in forestry: from modeling complex to the qualitative multivariate classification.

- <http://www.isafa.it/scientifica/retineurali.htm>
- Skidmore, A. K., B. J. Turner, W. Brinkhof, W. Knowles, 1997: Performance of a neural network: mapping forests using GIS and remotely sensed data. Photogrammetric Engineering and Remote Sensing, 63: 501–514.
- St-Onge, B., F. Cavayas, 1997: Automated forest structure mapping from high resolution imagery based on directional semivariogram estimates. Remote Sensing of Environment 61, pp. 82–95.
- Verbeke, L. P. C., F. M. B Van Coillie, R. R. De-Wulf, 2006: Object-based forest stand density estimation from very high resolution optical imagery using wavelet-based texture measures. In: 1st International Conference on Object-based Image Analysis (OBIA 2006).
- Wang, Y., D. Dong, 1997: Retrieving forest stand parameters from SAR backscatter data using a neural network trained by a canopy backscatter model. International Journal of Remote Sensing, 18: 981–989.
- Wulder, M., K. Niemann, D. Goodenough, 2000: Local maximum filtering for the extraction of tree locations and basal area from high spatial resolution imagery. Remote Sensing of Environment 73, pp. 103–114.
- Xiangcheng, M., Yingbin Zou, Wei Wei, Ke-ping Ma, 2005: Testing the generalization of artificial neural networks with cross-validation and independent-validation in modelling rice tillering dynamics. Ecological Modelling 181, 493–508.
- Osnova gospodarenja G. J. "Jamaričko brdo", važnost 1. 1. 2002. - 31. 12. 2011.
- Pravilnik o uređivanju šuma. NN 111/06.

SUMMARY: In the field of remote sensing the results of research undertaken with the purpose of determining quantitative and qualitative stand parameters showed the usefulness of artificial neural networks (Ardö et al. 1997, Skidmore et al. 1997, Wang & Dong 1997, Moisen & Frescino 2002, Ingram et al. 2005, Joshi et al. 2006, Kuplich 2006, Verbeke et al. 2006, Klobučar et al. 2008) as an alternative approach to classical statistical methods.

This paper explores the possibility of estimating and distributing stand density using methods of artificial neural networks. These methods involve particular textural features of first and second order histograms on a digital ortophoto compiled from black and white aerial photographs at an approximate scale of 1:20,000. The paper is also aimed at collecting data with an acceptable accuracy, which will reduce material investments. Research encompassed the area of the MU "Jamaričko Brdo", Lipovljani forest administration. Cyclic surveying was conducted in 2000.

In order to determine textural features of first and second order histograms, a sample was cut out from a digital ortophoto for 80 stand scenes (compartments/subcompartments) in management classes of pedunculate oak, sessile oak and common beech of the fourth (the most common), fifth and sixth age class.

A multi-layer perceptron was used to solve the problem of stand density estimation. A multi-layer perceptron is a neural network without feedback connections, where supervised learning is carried out with the error back propagation algorithm.

An early stopping method was applied to improve generalization. The early stopping method is a statistical cross-validation method in which the available data are divided into three sets: training, validation and testing set. Of the overall dataset, 50 % (or 40 compartments/subcompartments) relates to the training set, whereas the two remaining datasets were divided equally: 25 % (20 compartments/subcompartments) relate to the validation set and 25 % (20 compartments/subcompartments) to the testing set.

There are numerous variations of error back propagation algorithms. As for the early stopping method, it is not advisable to use an algorithm which converges too rapidly (Xiangcheng et al. 2005, Demuth et al. 2006). Consequently, two algorithms were used: resilient back-propagation and scaled conjugate gradient algorithm.

Prior to training the neural network itself, the data were preprocessed. In this sense, two operations were performed using MATLAB functions: normalization of input-output values and analysis of the main components of input values.

Training encompassed a total of seven algorithm models with error back propagation with one or two hidden layers containing a different number of hidden neurons. Different activation functions were also applied in hidden and output layers.

Self-organizing neural network was used to control densities according to their distribution into three categories (normal, less than normal, poor). To study the applicability of this neural network, 80 compartments/subcompartments were divided into two sets: training set and testing set, each consisting of 40 compartments/subcompartments. The data were preprocessed before the neural network was trained, just as was the case with the multilayer perceptron.

Textural features of first order histograms (arithmetic means, standard deviation, smoothness, third moment, evenness and entropy) and second order histograms (absolute value of difference, inertia, covariance, entropy and energy) were used as input data for the neural network, whereas output density values were taken from the Management plan.

Output values may also be represented as the number of trees, basal area or volume per hectare or as some other quantitative and qualitative stand values. Stand density was used as an output value for two reasons: a) poorer spectral features of the applied photographs, and b) the fact that, from the aspect of the forestry profession, the photographs were obtained in the unfavorable period (time of the year in which the ground is the least covered with vegetation).

To test the difference in stand density values between the data from the Management plan and the optimal model of artificial neural network, the analysis of variance for repeated measurements was used.

Research confirmed good generalization characteristics of a multilayer perceptron in density estimation, as well as the fact that a self-organizing neural network can be used to control and distribute stand densities. The applied procedure of density estimation achieves an acceptable accuracy and a high degree of automatism, which removes the subjective nature of classical remote sensing methods.

This research confirmed the advantages and disadvantages of artificial neural networks. The advantages are as follows: it is not necessary to know data models, the networks can be used to analyze new conditions, and they tolerate imperfect data. The disadvantages are: the need to determine optimal architecture and the impossibility of estimation outside the scope of learning data values. However, despite their numerous advantages, artificial neural networks will not completely replace classical statistical methods. Instead, a dual approach and integration of these two techniques in decision making processes will be a very useful tool in forest resource management of the 21st century. They are currently broadly applied, so we could say that this is a time of transition to the technology of artificial neural networks. Consequently, forestry of the Republic of Croatia should make broader use of this new technology.

Key words: artificial neural networks, remote sensing, cyclic aerial photographs, density, texture