

GDK 91(497.12)

Prispelo / Received: 03.09.2002

Sprejeto / Accepted: 02.10.2002

Izvirni znanstveni članek

Original scientific paper

UPORABA MULTISPEKTRALNIH SATELITSKIH POSNETKOV IN METOD GIS ZA ZAZNAVANJE TER NAPOVED ZARAŠČANJA

Andrej Kobler*, Gal Kušar*, Milan Hočevar*

Izvleček:

Na regionalni ravni smo s pomočjo podatkov satelita *Landsat TM* in z intenzivno izrabo že obstoječih kartnih ter GIS podatkovnih virov preizkušali možnosti racionalnega ugotavljanja sprememb gozdnatosti v obdobju 1975 – 1995. S prostorskim regresijskim modelom smo izdelali napoved zaraščanja po trendu za naslednjih 20 let. Zaraščanje smo zabeležili kot razliko med položajem gozdnega roba v dveh obdobjih, 1975 in 1995. Stanje iz leta 1975 smo pridobili iz arhivskih kart, stanje za leto 1995 pa smo ugotovili z numerično klasifikacijo posnetka satelita *Landsat TM*. Postopek klasifikacije smo v fazah, ki jemljejo največ časa, pospešili z uporabo strojnega učenja. Skupna tematska točnost karte gozdov za leto 1995 znaša 82 %, pri agregaciji v gozd / negozd pa 91 %. Polovica gozdnega roba na karti leži do 14 m daleč od prave lege, povprečno odstopanje od prave lege znaša 26,6 m. Med letoma 1975 in 1995 se je zaraslo 37 % kmetijskih površin. Regresijski model pojasnjuje 57 % variabilnosti zaraščanja. Napoved po trendu kaže, da bo v obdobju 1995 – 2015 zaraščanje najbolj intenzivno v občini Divača (52 %); v občinah Postojna, Cerknica in Pivka bo gozd porasel 36 % – 41 % kmetijskih površin.

Ključne besede: zaraščanje, klasifikacija rabe tal, GIS, regresijski model, Notranjska, Primorska

DETECTION AND PREDICTION OF SPONTANEOUS AFFORESTATION USING MULTISPECTRAL SATELLITE DATA AND GIS METHODS

Abstract:

Various options for streamlining forest cover change detection for the period 1975 – 1995 at the regional level were tested, based on *Landsat TM* satellite data and on existing maps and GIS layers. Using a spatial regression model, spontaneous afforestation was forecasted for the next 20 years. Forest change was determined with map differencing, using maps from 1975 and 1995. The 1975 forest border was acquired from legacy maps. The 1995 forest border was derived by classification of a *Landsat TM* satellite image. Machine learning was used in some steps of classification in order to streamline the procedure as much as possible. Overall, thematic accuracy of the 1995 map was 82 %. When nomenclature was aggregated to only forest / non-forest, the accuracy increased to 91 %. Half of the mapped forest border was within 14 m of the true location. The average departure from the true location was 26,6 m. Between 1975 and 1995, 37 % of agricultural land was lost to spontaneous afforestation. The regression model explains 57 % of the afforestation variability. In the next 20 years, the most heavily afforested municipality will be Divača (52 % afforestation of the present agricultural land), followed by Postojna, Cerknica, and Pivka (36 % to 41%), according to the current trend.

Key words: spontaneous afforestation, classification of land use, GIS, regression model, Notranjska region, Primorska region

* Gozdarski inštitut Slovenije, Večna pot 2, 1000 Ljubljana, SVN

**VSEBINA
CONTENTS**

1	UVOD	
	INTRODUCTION	279
2	METODE	
	METHODS	280
3	REZULTATI	
	RESULTS	295
4	RAZPRAVA	
	DISCUSSION	301
5	SUMMARY	303
6	VIRI	
	REFERENCES	304
	ZAHVALA	
	ACKNOWLEDGEMENTS	308

1 UVOD INTRODUCTION

Kulturna krajina zavzema največji del slovenskega ozemlja; v splošnem jo danes spreminjata dva procesa – človekovo poseganje v prostor, ob umikanju človeka pa narava s ponovnim osvajanjem opuščeni zemljišč. Kmetijska pridelava se prostorsko vse bolj oži in ob tem vse bolj intenzivira. Posledice se kažejo v ekološkem osiromašenju in homogenizaciji intenzivno obdelanih območij; istočasno se v območjih z neugodnimi razmerami za kmetovanje (takih je v Sloveniji 60 % kmetijskih površin) opuščena kmetijska zemljišča zaradi ugodne klime in rastnih razmer zaraščajo z gozdom. Opuščanje kmetijskih zemljišč poteka že od konca 19. stoletja, posebej pa se je okrepilo po drugi svetovni vojni. Zaradi razdrobljene posesti in razgibanega reliefa, ki zmanjšujeta ekonomičnost kmetijske pridelave, ter zaradi socialnih sprememb na podeželju, je tudi v prihodnosti mogoče pričakovati nadaljevanje zaraščanja.

Ustavitev zaraščanja in odseljavanja prebivalstva z zagotovitvijo razvoja ruralnih območij je eden izmed osnovnih ciljev slovenskega programa reforme kmetijske politike. Ohranitev poseljene in pestre kulturne krajine je predvidena v Nacionalnem programu varstva okolja (ČERNE / TURK 1999). Na mednarodni ravni je ohranjanje estetskih in ustvarjenih vrednot krajine kot del trajnostnega razvoja naravne in kulturne dediščine vključeno med smernice Evropske unije za uravnotežen prostorski razvoj. Odnos med naravnim in družbenim okoljem je obravnavan tudi v Agendi 21, sprejeti na konferenci o okolju in razvoju leta 1992 v Riu de Janeiru, ter v evropskim razmeram prilagojeni Helsinški deklaraciji iz leta 1993 (GOLOB 1998).

Spontano zaraščanje, ki v Sloveniji večinoma poteka nenadzorovano, je potrebno učinkoviteje nadzorovati. Potreben pogoj za to je učinkovit sistem velikoprostorskega zasledovanja sprememb pokrovnosti tal, kar danes omogoča daljinsko zaznavanje (predvsem s pomočjo satelitov). Cilj naše raziskave je bil iz podatkov satelita Landsat TM na regionalni ravni prikazati možnosti racionalnega ugotavljanja sprememb gozdnatosti v obdobju 1975 – 1995. Pri tem smo želeli v največji možni meri uporabiti že obstoječe podatkovne vire – GIS baze podatkov, tematske in topografske karte. Tako smo želeli skrajšati potreben čas dela in hkrati izboljšati točnost rezultatov.

2 METODE METHODS

2.1 UVOD V METODE INTRODUCTION IN THE METHODOLOGY

Z večanjem radiometrične, prostorske, spektralne in časovne ločljivosti satelitskih posnetkov vse lažje pridemo do točnih, podrobnih ter uporabnih informacij o objektu, ki nas zanima; hkrati potrebujemo vse zmogljivejši računalniški sistem, vse zmogljivejše algoritme za obdelavo slik, več časa za obdelavo in več znanja. Podatki satelita Landsat TM optimalno zadoščajo našim potrebam na regionalni ravni. V preglednici 1 so našteje nekatere lastnosti primerljivih satelitov.

Preglednica 1: Značilnosti senzorjev nekaterih najpomembnejših satelitov v optičnem in infrardečem (IR) delu spektra za raziskave na regionalni ravni

Table 1: Features of the most important satellite sensors in optical and infrared (IR) spectra for regional level studies

Satelit <i>Satellite</i>	Landsat TM*	SPOT4**	IRS-1C
Prostorska ločljivost <i>Spatial resolution</i>	30 m (VIS, IR)*** 120 m (TIR)	10 m (PAN) 20 m (VIS, IR)	5,8 m (PAN) 23 m (VIS, NIR) 70 m (SWIR)
Spektralni obseg / <i>Spectral range</i>	0,45-12,5 μm	0,51 – 0,73 μm (PAN) 0,50 – 0,89 μm (VIS, IR)	0,50 – 0,75 μm (PAN) 0,52 – 1,70 μm (VIS, NIR)
Število kanalov / <i>Number of channels</i>	6 (VIS, IR) 1 (TIR)	1 (PAN) 3 (VIS, IR)	1 (PAN) 4 (VIS, NIR, SWIR)
Časovna ločljivost / <i>Temporal resolution</i>	16 dni	26 dni / <i>days</i> (3 dni z usmerjanjem)	24 dni / <i>days</i> (5 dni z usmerjanjem)
Velikost slike / <i>Geographical coverage</i>	185 x 172 km	60 x 60 km	70 x 70 km (PAN) 142 x 142 km (VIS, NIR, SWIR)
Stereo zmožnost / <i>Stereo capability</i>	Ne / <i>No</i>	Da / <i>Yes</i>	Da / <i>Yes</i>

* Med potekom projekta se je pojavila izpopolnjena različica Landsat 7 ETM+, katere prednosti so predvsem dodan pankromatski kanal s 15-metrsko ločljivostjo, izboljšana ločljivost kanala TIR (60 m) in boljša kalibracija senzorjev

** Novejši satelit SPOT5, izstreljen 3. maja 2002, ima prostorsko ločljivost izboljšano na 5 m (PAN) in 10 m (VIS, IR)

*** Pomen kratic: VIS = vidni del spektra, IR = infrardeči del spektra, NIR = bližnji IR, SWIR = kratkovalovni IR, TIR = termični IR

Pri digitalni obdelavi slik objekte prepoznavamo na osnovi primarnih slikovnih elementov – vrednosti posameznih pikslov v različnih delih spektra; v zadnjem času raziskovalci razvijajo metode, ki zmorejo upoštevati tudi ploskovne elemente, kot so oblike, dimenzije, tekstura, struktura, stereoskopski efekt in prostorski odnosi med objekti (HOČEVAR 1993).

V nasprotju z analogno fotointerpretacijo, kjer lahko izkoristimo vse slikovne elemente v prostorski povezavi, pri tradicionalnih načinih digitalne analize slike upoštevamo le točkovne slikovne elemente – t.j. vrednosti posameznih pikslov. Ti načini temeljijo na parametričnih metodah prepoznavanja spektralnih razredov (določene spektralne vrednosti, ki opisujejo določen informacijski razred), in sicer z nenadzorovano ali nadzorovano klasifikacijo (HOČEVAR 1993, RICHARDS 1993). Prepoznavanje oz. poimenovanje spektralnih razredov pri nenadzorovani klasifikaciji je zaradi delovne intenzivnosti problem, kateremu je pozornost posvečalo mnogo avtorjev. ZEFF in MERRY (1993) sta poimenovanje izpeljala interaktivno s prekrivanjem barvne kompozitne satelitske slike s sliko, ki prikazuje spektralne razrede, in hkratnim upoštevanjem lokacije posameznega spektralnega razreda v dvodimenzionalnem spektralnem prostoru (Landsat TM – kanala 3 in 4). Velik pomen sta dala interpretatorjevemu poznavanju terena. STOMS *et al.* (1998) so določali vegetacijski pokrov iterativno s pomočjo vegetacijskih kart; metoda naj bi bila neobčutljiva na variabilnost zaradi različne fenologije v posameznih letih. VOGELMANN / SOHL / HOWARD (1998) so v severovzhodnem delu ZDA za členjenje preširokih spektralnih razredov uporabili RGB-kompozitno sliko Landsat TM, aeroposnetke in dodatne GIS-podatke (senčen relief, raba tal, gostota naseljenosti itd.). Metoda je učinkovita in daje dobre rezultate, vendar zahteva veliko interpretatorjevih posegov ter je delovno zelo intenzivna. Izredno časovno zahtevnost faze poimenovanja potrjuje tudi BELWARD (1995), ki poroča o porabljenih nekaj človek-letih dela za interpretacijo spektralnih razredov za zelo generalizirano globalno karto pokrovnosti.

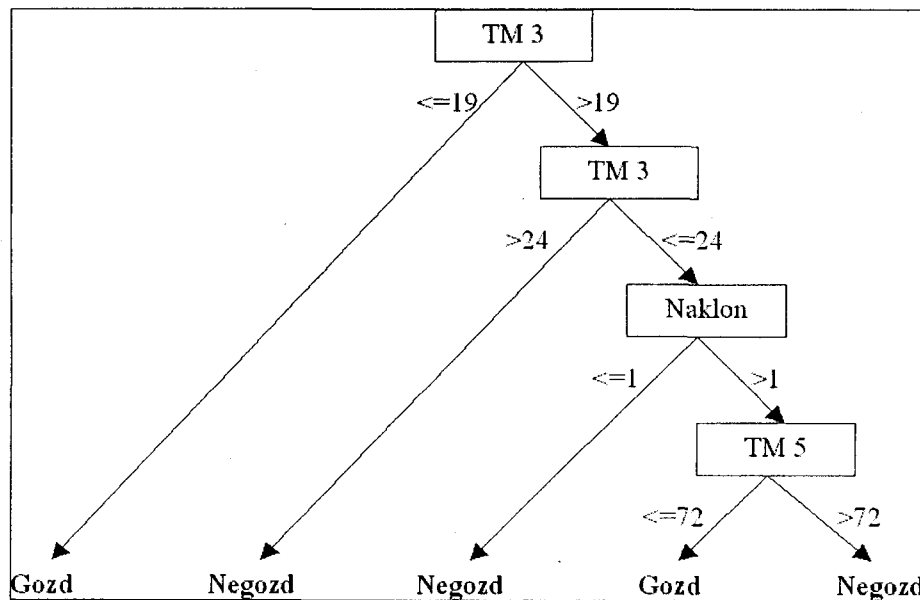
Parametrične metode klasifikacije slik so primerne le za numerično podane podatke, ki pogosto ne vsebujejo vseh potrebnih informacij za kakovostno (točno in vsebinsko podrobno) klasifikacijo. Mnoge dodatne informacije vsebujejo tematski GIS-sloji (npr. sestojne, geološke, pedološke in hidrološke karte). Za obdelavo teh informacij je potreben drugačen pristop, saj imajo nekateri GIS-sloji zvezne merske skale (npr. višine na

digitalnem modelu reliefa), drugi pa vsebujejo diskretne podatke (npr. tipi tal na pedološki karti). Avtorji predlagajo različne metode – npr. neparametrične različice nadzorovane klasifikacije največje verjetnosti; vodeno klasifikacijo na osnovi pravil, ki so lahko vsebovana v ekspertnem sistemu (t.i. *rule-based* klasifikacije; WILSON 1997, VOGELMANN / SOHL / HOWARD 1998); uporabo strojnega učenja, kamor med drugim spadajo nevronske mreže (CIVCO 1993, BRUZZONE *et al.* 1997, GONG 1996, SKIDMORE *et al.* 1997) in avtomatizirana gradnja baz znanja za ekspertne sisteme za klasifikacijo (AL-GARNI 1994, HUANG / JENSEN 1997, FRIEDL / BRODLEY 1997, HUANG 1998).

Pri vodeni klasifikaciji procesorju posredujemo prostorske podatke skupaj z bazo znanja (ekspertni sistem), ki smo jo pridobili od strokovnjakov za posamezno področje in smo jo preoblikovali v računalniku razumljivo obliko. Glavni problem ekspertnih sistemov je ozko grlo pri zbiranju znanja in njegovi pretvorbi v obliko, primerno za računalnik. Možno rešitev ponuja strojno učenje kot eno od obetavnih polj znotraj področja umetne inteligence. Cilji strojnega učenja so v splošnem (HUANG 1998):

1. razvrstiti neznane primere na podlagi podobnih, že rešenih primerov;
2. izboljšati rezultate klasifikacije na podlagi prejšnjih napak;
3. pridobivanje novih sposobnosti na podlagi opazovanja in oponašanja ekspertov.

Strojno učenje zajema več pristopov, od katerih se bomo omejili le na simbolno učenje. S simbolnim učenjem iz množice primerov, ki opisujejo nek koncept, nastane posplošen opis tega koncepta. Tak opis (lahko je v obliki klasifikacijskih pravil, pogosto pa v obliki odločitvenih dreves) lahko vključimo v bazo znanja ekspertnega sistema, ki ga nato uporabimo za klasifikacijo ali za napovedovanje. Odločitvena drevesa (slika 1) napovedujejo vrednost diskretne odvisne spremenljivke na podlagi vrednosti neodvisnih spremenljivk, ki so lahko zvezne (npr. naklon terena, sivinski ton slike) ali pa diskretne (npr. lastništvo, tip tal). Metoda ne predvideva določene porazdelitve; obdela lahko podatke (lahko so tudi medsebojno odvisni) v različnih merskih skalah. Le-to so lastnosti, ki jih potrebujemo, če v klasifikacijo multispektralnih podatkov vključimo tudi GIS-baze podatkov. Številni avtorji so dokazali, da je klasifikacija z odločitvenimi drevesi robustna in učinkovita metoda za klasifikacijo pokrovnosti, ki daje dokaj točne rezultate (QUINLAN 1986, AL-GARNI 1994, HUANG / JENSEN 1997, FRIEDL / BRODLEY 1997, DeFRIES *et al.* 1998, HUANG 1998, VARLYGUIN *et al.* 2001).



Slika 1: Primer enostavnega odločitvenega drevesa; sistem odloča na podlagi GIS podatkov in spektralnih vrednosti v posameznih kanalih


Figure 1: Example of a simple decision tree. The system decides based upon GIS data and image channel values

Podlaga za strojno učenje je reprezentativna množica učnih podatkov, ki opisuje realni sistem. Pri običajni metodi induktivnega učenja odločitvenih dreves, t.j. od vrha navzdol (*top down induction of decision trees, TDIDT*), algoritem napreduje rekurzivno, začenši s celotno množico učnih primerov. Pri vsakem koraku kot koren (pod)drevesa izbere najbolj informativno neodvisno spremenljivko in množico razdeli glede na vrednosti te spremenljivke. Pri diskretnih spremenljivkah se tvori veja za vsako vrednost spremenljivke, pri zveznih pa algoritem ugotovi ustrezeni prag. Gradnja drevesa se ustavi, ko so klasificirani vsi učni primeri ali, ko je zadovoljen kak drug kriterij za ustavljanje. Končne veje drevesa imenujemo listi. Pomemben mehanizem, ki preprečuje pretirano prilagajanje dreves učnim podatkom (*over-fitting*), je obvejevanje (*pruning*). Običajno v ta namen določimo minimalno število primerov, ki ga mora opisovati vsak list drevesa, ali pa določimo stopnjo zaupanja za ocene točnosti posameznih listov. Obstaja vrsta sistemov za indukcijo odločitvenih dreves iz primerov – npr. CART (BREIMAN *et al.*

1984), ASSISTANT (CESTNIK / KONONENKO / BRATKO 1987) in C4.5 (QUINLAN 1993). Med njimi je najbolj poznan C4.5, njegov naslednik C5 pa je trenutno najbolj izpopolnjen sistem za indukcijo odločitvenih dreves. Verzija C5, ki deluje v okolju MS Windows, se imenuje See5.

2.2 OBMOČJE RAZISKAVE STUDY AREA

Območje raziskave (slika 2) je veliko 47 x 34 km (159.800 ha) in zajema širše območje občin Cerknica, Postojna, Pivka in Divača. Območje smo izbrali, ker je znano po neugodnih naravnih danostih za kmetijsko obdelavo in je zato zaraščanje tu najintenzivnejše v slovenskem prostoru (CUNDER 1998).



Slika 2: Območje raziskave v jugozahodni Sloveniji

Figure 2: Study area in south-western Slovenia

2.3 ZAZNAVANJE ZARAŠČANJA V OBDOBJU 1975 – 1995

DETECTION OF SPONTANEOUS AFFORESTATION DURING 1975 – 1995

Zaraščanje smo zabeležili kot razliko med položajem gozdnega roba v dveh obdobjih – v letih 1975 in 1995. Celotno analizo smo izpeljali pri prostorski ločljivosti 25 m, ki ustreza

ločljivosti satelitske ortoslike Landsat TM. Območje raziskave je prekrito z rastrom 1880 x 1360 pikslov.

2.3.1 Karta gozda za leto 1995

The 1995 Forest Map

Karto gozda za leto 1995 smo izdelali z numerično klasifikacijo ortorektificiranega posnetka satelita Landsat TM (preglednica 2). Ortorektificirana slika je dediščina projekta *CORINE Land Cover Slovenia* (EC 1997, NLR 1997, HOČEVAR *et al.* 2001). Sami smo opravili še radiometrično korekcijo, katere rezultat naj bi bila (seveda le v idealnem primeru) slika, na kateri so slikovne vrednosti zgolj odsev spreminjanja pokrovnosti površja Zemlje, ne pa tudi osvetljenosti reliefa ali propustnosti atmosfere. Zaradi zapletenosti in negotovih rezultatov smo se odločili, da zanemarimo korekcijo atmosferskih vplivov, opravili pa smo topografsko normalizacijo (korekcijo neenake osvetljenosti zaradi vplivov reliefa). Uporabili smo Minnaertovo metodo (SMITH / LIN / RANSON 1980), implementirano v programu SILVICS 1.0 (McCORMICK 1999). Topografske spremenljivke smo izpeljali iz rastrskega digitalnega modela reliefa (DMR100) s horizontalno ločljivostjo 100 x 100 m (GURS 1995a).

Preglednica 2: Glavni podatki o uporabljenem satelitskem posnetku Landsat TM

Table 2: *Description of the Landsat TM image used in this study*

Št. slike / <i>Scene ID</i>	5191028009520710
Plovilo / <i>Spacecraft</i>	5
Pot / <i>Path</i>	191
Vrsta / <i>Row</i>	28
Datum / <i>Acq Date</i>	26/07/95
Ura / <i>Acq Time (GMT)</i>	08:56:31
Azimet sonca / <i>Sun Azimuth</i>	12208
Elevacija sonca / <i>Sun Elevation</i>	5151

Zaraščanje se v prostoru širi zvezno, zato je težko začrtati jasne meje med gozdom in negozdom tako v naravi kot tudi na satelitski sliki. Določili smo naslednje štiri informacijske razrede (le-ti ustrezajo glavnim sukcesijskim fazam zaraščanja) v končni nomenklaturi karte gozda za leto 1995: *negozd*, *opuščeni travnik*, *grmišče* in *gozd*. Razred negozd smo zaradi njegove heterogenosti dodatno razčlenili na podrazrede

neporaslo, voda, mokrišče in obdelano; tako smo v vmesnih fazah klasifikacije obravnavali sedem razredov pokrovnosti. Šele v končni fazi smo sedem razredov ponovno agregirali nazaj v štiri glavne razrede.

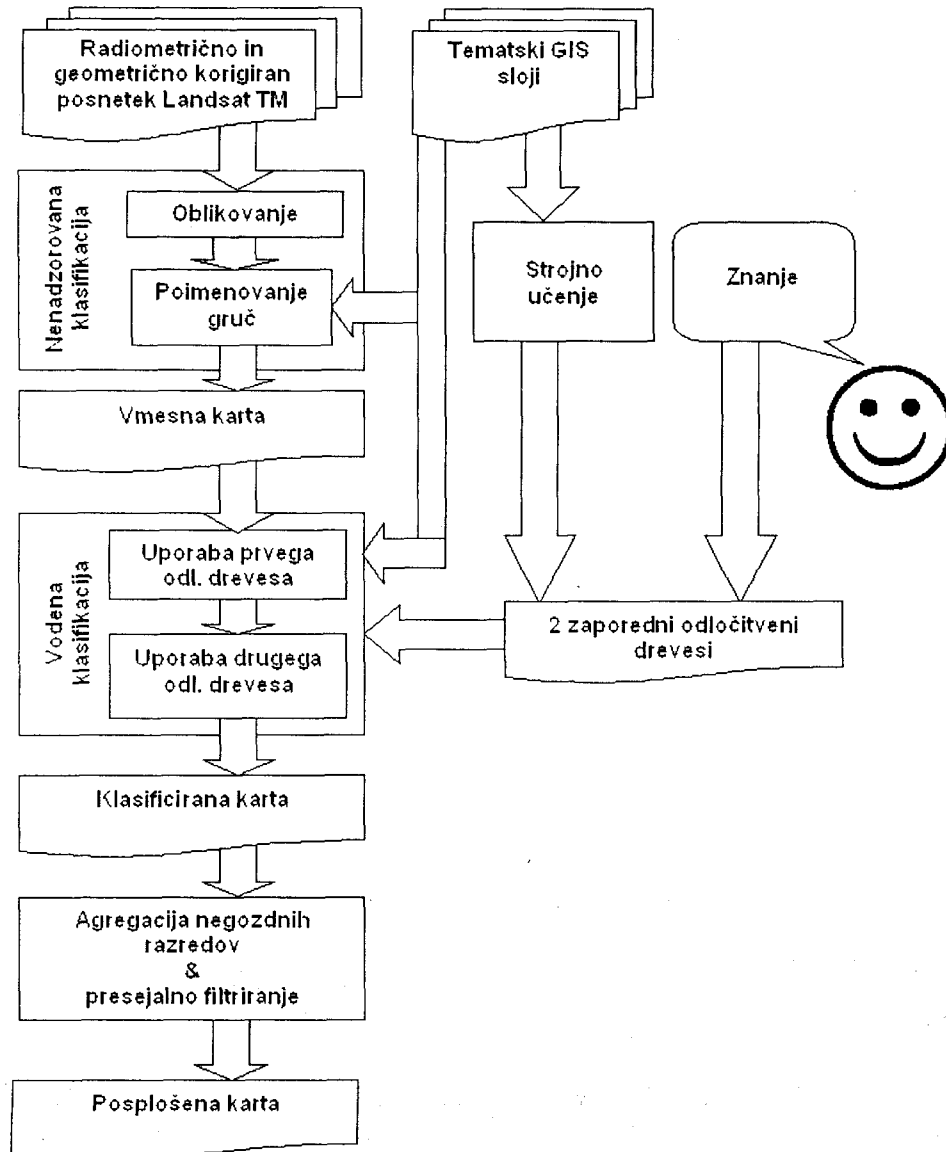
Klasifikacija je bila sestavljena iz dveh glavnih zaporednih faz – nenadzorovane klasifikacije multispektralne slike Landsat TM in vodene klasifikacije na podlagi pravil z upoštevanjem dodatnih GIS-slojev. Sledila je agregacija negozdskih razredov in nato generalizacija majhnih površin s presejalnim filtriranjem (slika 3). Za poenostavitev postopka smo z uporabo strojnega učenja avtomatizirali nekatere faze, ki navadno jemljejo največ časa. Iz istega razloga smo privzeli bazo podatkov *CORINE Land Cover Slovenia* (CLC) kot referenčni vir podatkov za prvi grobi približek karte gozda. Preden smo bazo CLC uporabili v klasifikaciji, smo njeno nomenklaturo agregirali v bolj splošne razrede naše nomenklature – poimenovali smo jih CLC_G-razredi (preglednica 3). Nekatere (sestavljene) CLC razrede smo v obravnavi zanemarili – ti so označene s kodo 0.

Preglednica 3: Agregacija originalnih *CORINE Land Cover* (CLC) razredov v bolj splošne CLC_G razrede referenčne baze podatkov o pokrovnosti

Table 3: Aggregation of the original *CORINE Land Cover* (CLC) classes into the more generalized CLC_G classes of the reference land cover database

CLC	CLC_G*	CLC	CLC_G	CLC	CLC_G	CLC	CLC_G	CLC	CLC_G
111	Neporaslo	211	Obdelano	311	Gozd	411	Mokrišče	511	Voda
112	Neporaslo	212	Obdelano	312	Gozd	412	Mokrišče	512	Voda
121	Neporaslo	221	Obdelano	313	Gozd	421	Mokrišče	521	Voda
122	Neporaslo	222	Obdelano	321	Opušč. travnik	422	Mokrišče	522	Voda
123	Neporaslo	223	Obdelano	322	Gozd			523	Voda
124	Neporaslo	231	Obdelano	323	Grmišče				
131	Neporaslo	242	Obdelano	324	Grmišče				
132	Neporaslo	243	0	331	Neporaslo				
133	Neporaslo			332	Neporaslo				
141	0			333	Opušč. travnik				
142	0			334	Grmišče				
				335	Neporaslo				

* English translation of CLC_G classes: *Neporaslo* (eng. Unvegetated), *Obdelano* (eng. Agricultural land), *Opušč. travnik* (eng. Abandoned hay meadow), *Grmišče* (eng. Shrub), *Gozd* (eng. Forest), *Mokrišče* (eng. Wetland)



Slika 3: Potek klasifikacije satelitske slike

Figure 3: Flow – chart of the satellite image classification

V fazi nenadzorovane klasifikacije smo z oblikovanjem gruč (*clustering*) uvrstili piksele kanalov 2, 3, 4, 5 in 7 v "naravne", jasno razmejene spektralne razrede. Podfazo poimenovanja spektralnih razredov v informacijske razrede smo poenostavili tako, da smo vsak spektralni razred poimenovali kar po najbolj zastopanem CLC_G-razredu. Tako nastali vmesni rezultat je vseboval še precej napak, saj nekaterih informacijskih razredov (npr. grmišča) ni mogoče kvalitetno izločiti zgolj na podlagi slikovnih podatkov. Vendar je tudi vmesni rezultat predstavljal dober prvi približek kot osnovo za končno fazo klasifikacije z odločitvenimi drevesi.

Preglednica 4: GIS sloji, ki smo jih uporabili pri klasifikaciji

Table 4: GIS layers used in classification

Ime / Name	Pomen / Meaning
CLC_G	Površinski pokrov – agregirani CLC razredi (<i>aggregated CORINE land cover</i>).
NENADZOR_REZ	Rezultat 1. faze klasifikacije (t.j. nenadzorovane klasifikacije) (<i>Nonsupervised classification result</i>).
GOZD75	Prisotnost / odsotnost gozda v letu 1975 (GURS 1995b) (<i>Forest presence / absence</i>).
DMR	Digitalni model reliefa s horizontalno ločljivostjo 100 x 100 m (GURS 1995a) (<i>Digital elevation model</i>).
NAKLON	Naklon reliefa, izražen v stopinjah, izpeljan iz DMR (<i>Relief slope</i>).
LAPLACE	Razgibanost reliefa, izpeljana z Laplaceovim filtrom iz digitalnega modela reliefa (<i>Terrain roughness</i>).
INSOLACIJA	Letna globalna insolacija [MJ/m^2] (GABROVEC 1996) (<i>Yearly global insolation</i>).
POP_GOSTOTA	Gostota prebivalstva, izražena na ravni geografske mezoregije (PERKO / OROŽEN-ADAMIČ 1998) (<i>Population density</i>).
POP_STAR_INDEKS	Razmerje prebivalstva (<20 let) / (>60 let) (prilagojeno iz PERKO / OROŽEN-ADAMIČ 1998) (<i>Ratio number of inhabitants (<20 y.o.) / (>60 y.o.)</i>).
ODD_NAS_AC	Oddaljenost od najbližjega naselja ali avtocestnega odseka [m] (izpeljana iz GURS 1995b) (<i>Proximity to settlements or to highway</i>).
ODD_VODA	Oddaljenost od najbližjega vodotoka ali jezera [m] (izpeljana iz GURS 1995b) (<i>Proximity to lake or stream</i>).
ODD_JEZERO	Oddaljenost od najbližjega jezera [m] (izpeljana iz GURS 1995b) (<i>Proximity to lake</i>).
TM2	Ortorektificirani in topografsko normalizirani kanali slike LANDSAT TM, posnete 26. julija 1995 (EC 1997, NLR 1997) (<i>Ortorectified and radiometrically corrected Landsat TM image channels</i>).
TM3	
TM4	
TM5	
TM7	
NDVI	Vegetacijski indeks (<i>Normalized Difference Vegetation Index</i>) $\text{NDVI} = (\text{TM4} - \text{TM3}) / (\text{TM4} + \text{TM3})$; izračunan je iz slikovnih kanalov pred radiometrično korekcijo.

V drugi fazi klasifikacije – nadzorovani klasifikaciji – smo uporabili dodatne informacije, vsebovane v tematskih GIS slojih (preglednica 4); na njihovi osnovi smo zgradili dve odločitveni drevesi, ki zaporedoma izboljšujeta rezultat nenadzorovane klasifikacije. Odločitveni drevesi smo zgradili s kombiniranjem rezultatov strojnega učenja iz primerov

(z znanim CLC_G razredom) in interpretatorjevega poznavanja raziskovalnega območja. Za strojno učenje smo uporabili program See5 podjetja RuleQuest.

Stopnja vzorčenja za učni vzorec je bila 5-odstotna (127.537 primerov). Izbrali smo stratificiran naključni vzorec, pri čemer je bilo število primerov enako za vsak stratum. Izbrana je bila največja stopnja vzorčenja, ki je še zagotavljala enakovredno zastopnost tudi majhnih stratumov. Območje raziskave smo stratificirali na podlagi agregirane baze CLC in globalne letne insolacije (GABROVEC 1996). Dobili smo 16 stratumov; kot kandidate za učni vzorec smo upoštevali le tiste piksele znotraj posameznega stratuma, ki se nahajajo dlje kot 100 m od meje stratuma. S tem smo se izognili možnim problemom nejasne pripadnosti pikselov na mejah CLC-poligonov, ki bi lahko nastopila zaradi nenatančnega razmejevanja pri pripravi baze CLC.

Odločitvena drevesa, ki so nastala kot rezultat strojnega učenja s programom See5, smo interaktivno popravljali. Pomembni vlogi strojnega učenja v tem procesu sta bili predvsem: (a) prepoznavanje pragov pri zveznih atributih oziroma neodvisnih spremenljivkah (npr. prag vrednosti NDVI, ki pomaga razločevati resnično obdelane površine znotraj razreda *obdelano* na karti, nastali v prvi fazi klasifikacije); (b) generiranje kompleksnih kombinacij kriterijev znotraj posameznih vej drevesa. Take kombinacije smo iskali z usmerjenim strojnim učenjem. To pomeni, da smo:

- uporabljali za strojno učenje le podvzorke, ki se nanašajo le na določeno vejo (npr. v neki veji smo razločevali razreda *mokrišče* in *gozd* le na podlagi učnega podvzorca, kjer velja $NENADZOR_REZ = mokrišče$ in $NAKLON = 0^\circ$);
- ustrezno prilagajali parametre obvejevanja v programu See5.

Hkrati smo pri vsaki spremembi drevesa:

- preverjali točnost obravnavane veje odločitvenega drevesa, kar smo storili z 10-kratnim navzkrižnim preverjanjem (*10-fold crossvalidation*); pri tem smo uporabljeni učni vzorec naključno razdelili na 10 delov, nato pa 10-krat generirali drevo iz 90 % vzorca, s preostalimi 10 % pa smo ocenili točnost klasifikacije;
- vizualno ocenjevali točnost rezultata (glede na lastno poznavanje terena).

Po opravljeni reklasifikaciji z odločitvenima drevesoma smo vse negozdne razrede agregirali nazaj v razred *negozd*. Znotraj homogenih površin so na karti preostajali še

izolirani piksli drugih razredov, zato smo karto s presejalnim filtrom posplošili na najmanjšo površino kartiranja 4 piksle oz. 0,25 ha. Presejalni filter deluje tako, da vse zaplate določene kategorije (v kontekstu vektorskega GIS bi jih poimenovali poligone), ki so manjši od izbranega praga, pridruži največji sosednji zaplati.

Oceno točnosti karte gozdov smo opravili s pomočjo neodvisnega kontrolnega vzorca, ki smo ga pridobili z interpretacijo letalskih posnetkov pod stereoskopom. Ocenjevali smo tako tematsko točnost izdelane karte kot tudi točnost delineacije gozdnega roba. Tematsko točnost smo ocenjevali s pomočjo matrike napak (CONGALTON 1991), točnost delineacije pa po CHRISMANU (1982) z metodo "epsilon pasu" (*epsilon band*). Porabo časa za zbiranje kontrolnih podatkov za oceno tematske točnosti smo zmanjšali z dvostopenjskim vzorčenjem v 10 slučajnostno razporejenih krožnih ploskvah s polmerom 1 km in z avtomatiziranim razmejevanjem – t.j. segmentacijo radiometrično korigirane satelitske slike. Segmentacija pomeni avtomatsko razčlenjevanje digitalne slike na homogene površine (McCORMICK 1999). Če predpostavimo, da homogena površina na sliki ustreza tudi homogeni pokrovnosti v naravi, si na tak način pri fotointerpretaciji prihranimo fazo razmejevanja; preostaja nam le še prepoznavanje razreda pokrovnosti znotraj izločenih homogenih površin.

Pri določitvi velikosti vzorca smo upoštevali priporočila (CONGALTON 1991), ki za površine pod 400.000 ha priporoča vsaj 50 vzorčnih enot na razred. Povprečni segment meri 1 ha oziroma 16 pikslov. Na aeroposnetkih cikličnega aerosnemanja, posnetih v letih 1994 in 1995, smo pod stereoskopom prepoznali razrede pokrovnosti za vse slikovne segmente.

Preglednica 5 prikazuje fotointerpretacijski ključ za prepoznavanje razredov pokrovnosti na aeroslikah. V ključu nastopata med drugim dominantna višina, ki jo opredeljujemo kot povprečno višino 25 dreves zgornjega sloja na površini 0,25 ha, in sklep krošenj, ki ga opredeljujemo kot delež prekrivanja tal s krošnjami vseh slojev.

Preglednica 5: Ključ za fotointerpretacijo aeroposnetkov

Table 5: Aerial imagery photointerpretation key

Je_ureditveno_območje_gozdov.:	Gozd
Ni_ureditveno_območje_gozdov.:	
Površina > 0,5ha:	
: Sklep > 75%:	
: ...Dominantna_višina > 5m:	Gozd
: Dominantna_višina ≤ 5m:	Grmišče
: Sklep ≤ 75%:	
: ...Lesnate_rastline_v_omejkih:	Negozd
: Lesnate_rastline_razpršene:	
: ...Sklep > 25%:	Grmišče
: Sklep ≤ 25%:	Opuščen_travnik
Površina ≤ 0,5ha:	
Sklep > 90%:	
: ...Dominantna_višina > 5m:	Gozd
: Dominantna_višina ≤ 5m:	Grmišče
Sklep ≤ 90%:	
: ...Lesnate_rastline_v_omejkih:	Negozd
: Lesnate_rastline_razpršene:	
: ...Sklep > 25%:	Grmišče
: Sklep ≤ 25%:	Opuščen_travnik

Iz matrike napak smo izračunali splošno točnost kot delež elementov na glavni diagonali matrike (t.j. delež pravilno klasificiranih pikslov) in producentovo ter uporabnikovo točnost za vsak informacijski razred (CONGALTON 1991). Producentova točnost (*producer's accuracy*) kaže verjetnost, da je posamezen piksel določenega razreda iz kontrolnega vzorca pravilno klasificiran; opredeljena je kot razmerje med številom pravilno klasificiranih pikslov v razredu (znotraj preseka s kontrolnim vzorcem) in številom pikslov razreda v kontrolnem vzorcu. Uporabnikova točnost (*user's accuracy*) je opredeljena kot razmerje med številom pravilno klasificiranih pikslov v določenem razredu in številom pikslov tega razreda na karti. Nakazuje zanesljivost klasifikacije za posamezen informacijski razred oziroma verjetnost, da informacijski razred piksla na karti dejansko ustreza stanju v naravi. Izračunali smo tudi indeks Kappa, ki kaže, v kolikšni meri so pravilno klasificirani piksli pravilni na račun dejanske skladnosti s kontrolnim vzorcem in ne na račun slučajne "pravilnosti" (LILLESAND / KIEFER 1994). Indeks Kappa je CONGALTON (1991) definiral kot:

$K = (\text{izmerjena splošna točnost} - \text{slučajnostno ujemanje}) / (1 - \text{slučajnostno ujemanje})$.

Vzorec za kontrolo točnosti delineacije gozdnega roba smo pridobili v istih 10 krožnih ploskvah s fotointerpretacijo gozdnega roba na aeroposnetkih pod stereoskopom. Ker nismo imeli na voljo letalskih ortoslik, smo potek linije gozdnega roba sproti vnašali na satelitsko ortosliko. Pravilen prenos iz stereomodela aeroposnetkov na satelitsko ortosliko smo zagotovili s pazljivim primerjanjem orientacijskih objektov na obeh slikah. Točnost delineacije smo ocenjevali z modificirano metodo "epsilon pasu" (*epsilon band*; CHRISMAN 1982). "Epsilon pas" je pas stalne širine okoli pravega gozdnega roba, v katerem se najverjetneje nahaja kartiran gozdni rob (DUNN / HARRISON / WHITE 1990). Viri se razhajajo glede širine "epsilon pasu": določna opredelitev (BLAKEMORE 1984) pravi, da je širina tega pasu taka, da zaobseže ves gozdni rob na karti ne glede na razdaljo od pravega roba. To je t.i. "epsilon pas" celotnega obsega (*range epsilon band*). Verjetnostna opredelitev pa pojmuje "epsilon pas" kot neko mero odklona od prave linije. Tako npr. CHRISMAN (1982) uporablja t.i. "pas epsilon medkvartilnega obsega" – t.j. širino, v kateri se nahaja 50 % linije gozdnega roba na karti (*interquartile range epsilon band*). V nadaljevanju prikazujemo rezultate glede na obe opredelitvi.

2.3.2 Karta gozda za leto 1975

The 1975 Forest Map

Karto iz leta 1975 smo pripravili z združitvijo geokodiranih skenogramov gozdnega sloja topografskih kart v merilu 1 : 50.000, ki jih je izdala Geodetska uprava RS (GURS) leta 1981. Gozdni rob na tej karti je bil povzet iz temeljnega topografskega načrta v merilu 1 : 5.000 (TTN5) iz različnih let, vendar lahko kot srednje leto zajema na TTN5 privzamemo sredino sedemdesetih let; v tem primeru gozdni rob ne zajema grmišč (KOS 2000 os. komunikacija).

2.3.3 Prepoznavanje površin v zaraščanju

Identification of the Afforested Areas

Površine v zaraščanju smo prepoznali s presekom kart gozdnega roba za leti 1975 (2 razreda) in 1995 (4 razredi). Dobili smo karto 20-letnega zaraščanja z osmimi presečnimi razredi. Karti zaraščanja smo zaradi potreb kasnejše analize dodali še površinsko pomembna razreda *naselja* in *vode*, povzeta iz topografske karte v merilu 1 : 50.000 (TK50) Geodetskega zavoda RS. Tako smo iz pomensko široke kategorije negozda izločili nekmetijske površine, s čimer smo omogočili korektnjši izračun stopnje zaraščanja. Karta zaraščanja za obdobje 1975 – 1995 torej vsebuje 10 razredov (preglednica 6).

Preglednica 6: Razredi karte zaraščanja v obdobju 1975 – 1995

Table 6: Nomenclature of the afforestation map for 1975 – 1995

Stanje (State) 1995						Stanje (State) 1975
		Gozd (Forest)	Grmišče (Shrub)	Opuščen travnik (Abandoned grassland)	Negozd (Nonforest)	
0. Naselje (Settlement)	9. Voda (Water)	8. Stalno gozd (Permanent forest)	7. Izključeno in zaraščeno (Cleared & afforested)	6. Izključeno in opuščeno (Cleared & abandoned)	5. Izključeno (Cleared)	Gozd (Forest)
		4. Zaraščeno (Already afforested)	3. V zaraščanju (In the process of afforestation)	2. V opuščanju (In the process of abandonment)	1. Stalno negozd (Permanent nonforest)	Negozd (Nonforest)

2.4 NAPOVED ZARAŠČANJA ZA OBDOBJE 1995 – 2015

FORECAST OF SPONTANEOUS AFFORESTATION DURING 1995 – 2015

Izdelali smo regresijski model, ki pojasnjuje intenzivnost zaraščanja v preteklem 20-letnem obdobju z različnimi prostorsko določenimi neodvisnimi spremenljivkami. Model smo uporabili za napoved prihodnjega zaraščanja po trendu za obdobje naslednjih 20 let (1995 – 2015). Prihodnje stanje smo z modelom napovedali tako, da smo stanje neodvisnih spremenljivk iz leta 1975 nadomestili z novim izhodiščnim stanjem leta 1995. Intenzivnost zaraščanja smo ponazorili z indeksom zaraščanja INDZAR, ki smo ga definirali kot odstotno razmerje med površino na novo nastalih gozdov oz. grmišč in izhodiščno kmetijsko površino v okolici vsakega piksla. Postavlja se vprašanje, kako velika naj bo okolica, znotraj katere računamo INDZAR. Pri odločitvi o velikosti okna smo upoštevali, da nam: (1) majhno okno omogoča preučevanje pojava zaraščanja v

velikem merilu, saj se zabriše le malo podrobnosti vhodne karte; (2) veliko okno v veliki meri zabriše lokalne fluktuacije, vendar pa s tem omogoči izdelavo modela z večjo napovedno močjo (višji koeficient korelacije R). S testi smo ugotovili, da optimalen kompromis med napovedovalno močjo modela (R) in njegovo prostorsko podrobnostjo zagotavlja krožno okno velikosti 41 x 41 pikslov, kar ustreza krogu s polmerom 0,5 km.

Osnova za regresijski model je bil slučajnost stratificiran vzorec; enota vzorčenja je bil piksel, stopnja vzorčenja je bila 5-odstotna, vsak stratum pa je bil zastopan z enakim številom pikslov. Prvi stratum so predstavljali razredi zaraščanja (t.j. razredi 3, 4 in 7) na karti zaraščanja za obdobje 1975 – 1995 (preglednica 6). Drugi stratum so predstavljale leta 1995 še nezaraščene kmetijske površine (razreda 1 in 2). Velikost celotnega vzorca je bila $n = 34.522$.

Zaradi načina izračuna odvisne spremenljivke INDZAR ima tudi prognostična karta zaraščanja ločljivost enako 1 km. To ne drži za razrede *gozd*, *naselje* in *voda*, ki so smiselno povzeti iz karte zaraščanja za obdobje 1975 – 1995.

Pri izboru pojasnjevalnih spremenljivk smo na začetku upoštevali tiste, za katere smo pričakovali, da so v kakršni koli neposredni ali posredni vzročni povezavi z zaraščanjem (preglednica 7).

Preglednica 7: Pojasnjevalne spremenljivke za napovedovanje zaraščanja

Table 7: Explanatory GIS variables for the afforestation forecast model

me Name	Pomen Meaning	Vir podatka Data source
NAKLPROC	Naklon terena, izpeljan iz DMR100 / <i>Terrain slope</i> [%].	GURS* 1995a
Z75	Gozdnatost [%] leta 1975 v okolici s polmerom 0,5 km / % <i>forests in 1975</i>	GURS 1995b
ZR75	Fragmentacija gozdnega roba leta 1975 v okolici s polmerom 0,5 km; definirana je kot delež [%] pikslov gozdnega roba v oknu 41 x 41 / <i>Forest border fragmentation</i>	A. Kobler
POVPOV81	Povprečna površina kmetije v KO v letu 1981 / <i>Average farm area</i> [ha].	T. Cunder, KIS**, 2000, os. kom.
DELCISTA81	Delež čistih kmetij v KO v letu 1981 / <i>Share of pure farms in 1981</i> [%].	T. Cunder, KIS, 2000, os. kom.
DELMESANA81	Delež kmetij z mešanim virom dohodka v KO v letu 1981 / <i>Share of mixed farms in 1981</i> [%].	T. Cunder, KIS, 2000, os. kom.
DELNEKMECK8	Delež dopolnilnih kmetij v KO v letu 1981 / <i>Share of supplemental farms in 1981</i> [%].	T. Cunder, KIS, 2000, os. kom.
DELBREZDSI81	Delež neaktivnih kmetij v letu 1981 / <i>Share of nonactive farms in 1981</i> [%].	T. Cunder, KIS, 2000, os. kom.

Preglednica 7: nadaljevanje

Table 7: (continuation)

Ime Name	Pomen Meaning	Vir podatka Data source
INDSTAR81	Indeks staranja v letu 1981 – razmerje [%] med številom prebivalcev, starejših od 65 let, in številom prebivalcev, starih do 14 let na ravni upravne občine / Ageing index in 1981, community level - % ratio Inhabitants >65 y.o. / < 14 y.o	A. Jakoš, UIRS***, 2000, os. kom.
NASDST	Zračna razdalja od piksla do najbližjega naselja / Proximity to settlements [m].	GURS 1995b
CESTEDST	Pravokotna razdalja od piksla do najbližje ceste; upoštevane so ceste na topografski karti 1:50.000 (GURS 1995b) / Proximity to roads [m].	GURS 1995b
GPR1981	Gostota prebivalcev na ravni občine / Population density at the community level [preb/km ²].	A. Jakoš, UIRS, 2000, os. kom.
IND8171	Indeks rasti prebivalstva v občini 1981 / 1971 / Population increase index 1981 / 1971 [%].	A. Jakoš, UIRS, 2000, os. kom.
IND8161	Indeks rasti prebivalstva v občini 1981 / 1961 / Population increase index 1981 / 1961 [%].	A. Jakoš, UIRS, 2000, os. kom.
GR75DIST	Oddaljenost piksla od najbližjega gozdnega roba [m] – stanje leta 1975 / Proximity to forest border in 1975	A. Kobler
DMR	Nadmorska višina / Elevation [m].	GURS 1995a

*GURS – Geodetska uprava RS,**KIS – Kmetijski inštitut Slovenije,***UIRS – Urbanistični inštitut RS.

3 REZULTATI RESULTS

3.1 ZAZNAVANJE ZARAŠČANJA V OBDOBJU 1975 – 1995

DETECTION OF SPONTANEOUS AFFORESTATION DURING 1975 – 1995

Odločitveni drevesi, s katerima smo reklasificirali rezultat nenadzorovane klasifikacije za leto 1995, prikazuje preglednica 8. Z drugim drevesom smo popravili nekatere napake, ki so še preostale po obravnavi s prvim drevesom. S presejalnim filtriranjem majhnih poligonov smo nato izdelali končno karto gozdov za leto 1995.

Preglednica 9 podaja matriko napak in iz nje izpeljano skupno točnost (82 %), producentove in uporabnikove točnosti ter Kappa statistiko (67 %). Če naše poimenovanje združimo iz štirih razredov na dva, tako da združimo razrede *negozd*, *opuščeni travniki* in *grmišča*, se delež pravilno klasificiranih pikslov poveča na 91 %, statistika Kappa pa na 81 % (preglednica 10). Podobno velja za producentovo in uporabnikovo točnost.

Preglednica 8: Odločitveni drevesi za zaporedno reklasifikacijo rezultatov nadzorovane klasifikacije

Table 8: Decision trees for stepwise reclassification of the results of the unsupervised classification

Odločitveno drevo 1	Odločitveno drevo 2
<pre> NENADZOR_REZ = Gozd: ...ODD_JEZERO = 0: : ...TM5 <= 43: Voda : : TM5 > 43: Mokrišče : ODD_JEZERO > 0: : ...NAKLON > 0: Gozd : : NAKLON = 0: : : ...TM5 <= 50: Gozd : : : TM5 > 50: Mokrišče NENADZOR_REZ = Obdelano: ...GOZD75 = Gozd: : ...NDVI <= 211: Obdelano : : NDVI > 211: Gozd : GOZD75 = Negozd: : ...NDVI > 156: Obdelano : : NDVI <= 156: : : ...ODD_NAS_AC <= 51: Nedoraslo : : : ODD_NAS_AC > 51: Obdelano NENADZOR_REZ = Mokrišče: ...NAKLON = 0: : ...TM5 <= 50: Gozd : : TM5 > 50: Mokrišče : NAKLON > 0: : ...ODD_JEZERO = 0: Mokrišče : : ODD_JEZERO > 0: : : ...TM5 <= 69: Gozd : : : TM5 > 69: Grmišče NENADZOR_REZ = Nedoraslo: ...ODD_NAS_AC > 195: Obdelano : ODD_NAS_AC <= 195: : ...ODD_NAS_AC <= 25: Nedoraslo : : ODD_NAS_AC > 25: : : ...NDVI <= 105: Nedoraslo : : : NDVI > 105: : : : ...ODD_JEZERO = 0: Voda : : : : ODD_JEZERO > 0: Obdelano NENADZOR_REZ = Grmišče: ...GOZD75 = Gozd: Gozd : ...TM5 <= 75: Gozd : : TM5 > 75: Grmišče GOZD75 = Negozd: ...NAKLON = 0: : ...ODD_VODA = 0: Mokrišče : : ODD_VODA > 0: : : ...NDVI <= 204: Mokrišče : : : NDVI > 204: Grmišče NAKLON > 0: : ...ODD_NAS_AC <= 430: Obdelano : : ODD_NAS_AC > 430: : : ...POP_GOSTOTA <= 64: Grmišče : : : POP_GOSTOTA > 64: Obdelano </pre>	<pre> DREVO1_REZULTAT* = Gozd: ...ODD_JEZERO > 0: Gozd : ODD_JEZERO = 0: Voda DREVO1_REZULTAT = Obdelano: ...NDVI <= 190: Obdelano : NDVI > 190: : ...TM5 <= 81: Opuščen travnik : : TM5 > 81: Obdelano DREVO1_REZULTAT = Voda: ...GOZD75 = Negozd: Voda : GOZD75 = Gozd: Gozd DREVO1_REZULTAT = Mokrišče: ...GOZD75 = Gozd: Gozd : GOZD75 = Negozd: Mokrišče DREVO1_REZULTAT = Grmišče: ...TM5 <= 80: Grmišče : TM5 > 80: Opuščen travnik </pre> <p>* Neodvisna spremenljivka DREVO1_REZULTAT v drugem odločitvenem drevesu vsebuje rezultat klasifikacije s prvim odločitvenim drevesom.</p>

Preglednica 9: Matrika napak za členitev prostora na 4 razrede pokrovnosti

Table 9: Error matrix for the 4 land cover classes

		Kontrolni vzorec Control sample				Skupaj Total	Uporabnikova točnost Users accuracy
		Negozd Nonforest	Opušeni travnik Abandoned grassland	Grmišče Shrub	Gozd Forest		
Rezultat klasifikacije Classification result	Negozd Nonforest	9.169	1.394	334	495	11.392	80%
	Opušeni travnik Abandoned grassland	1.241	1.843	303	536	3.923	47%
	Grmišče Shrub	497	963	862	987	3.309	26%
	Gozd Forest	691	707	986	29.072	31.456	92%
Skupaj Total		11.598	4.907	2.485	31.090	50.080	
Producentova točnost Producers accuracy		79%	38%	35%	94%		82%
Kappa indeks (Kappa index): 67 % (vsi razredi - All classes) 73 % (Negozd - Nonforest) 32 % (Opušeni travnik - Abandoned grassland) 30 % (Grmišče - Shrub) 82 % (Gozd - Forest)							

Preglednica 10: Matrika napak za členitev prostora na 2 razreda pokrovnosti

Table 10: Error matrix for the 2 land cover classes

		Kontrolni vzorec Control sample		Skupaj Total	Uporabnikova točnost Users accuracy
		Negozd + Opušeni travnik + Grmišče Nonforest + Abandoned grassland + Shrub	Gozd Forest		
Rezultat klasifikacije Classification	Negozd + Opušeni travnik + Grmišče Nonforest + Abandoned grassland + Shrub	16.606	2.018	18.624	89 %
	Gozd Forest	2.384	29.072	31.456	92 %
	Skupaj Total	18.990	31.090	50.080	
Producentova točnost Producers accuracy		87 %	94 %		91%
Kappa indeks (Kappa index): 81 % vsi razredi (All classes) 80 % Negozd + Opušeni travnik + Grmišče (Nonforest + Ab. grassl. + Shrub) 83 % Gozd (Forest)					

Ocena točnosti poteka linije gozdnega roba kaže, da medkvartilni epsilon pas sega 14 m na vsako stran pravega gozdnega roba. To pomeni, da je 50 % dolžine gozdnega roba na klasificirani karti gozda za leto 1995 do 14 m daleč od prave lege. "Epsilon pas"

celotnega obsega znaša 448 m, kar nakazuje največjo razliko med pravo lego gozdnega roba in lego na karti. Povprečno odstopanje od prave lege znaša 26,6 m.

V celotnem raziskovalnem območju se je med letoma 1975 in 1995 zaraslo 21.080 ha oziroma 37 % kmetijskih površin; to pomeni, da se je povprečno letno zaraslo 1,9 % kmetijskih površin oziroma 1054 ha. Zabeležena stopnja zaraščanja je torej še višja od stopnje zaraščanja v celotni Sloveniji, ki je v istem obdobju znašala 27 % (HOČEVAR / KOBLER / CUNDER 2001). Če je bila gozdnatost v raziskovalnem območju leta 1975 še 62 %, je do leta 1995 narasla na 75 %.

3.2 REGRESIJSKI MODEL ZARAŠČANJA IN NAPOVED ZARAŠČANJA V OBDOBJU 1995 – 2015

REGRESSION MODEL OF SPONTANEOUS AFFORESTATION AND AFFORESTATION FORECAST FOR 1995 – 2015


Spremenljivke, ki so v najtesnejši korelaciji z indeksom zaraščanja INDZAR, so G75, NASDST in GR75DIST (preglednica 7). Višji koeficient korelacije smo dobili, če smo drugo in tretjo spremenljivko transformirali, s čimer smo njuno porazdelitev približali normalni. Regresijski model je:

$$\text{INDZAR} = -69,0010 + 0,6203 \cdot G75 + 12,3643 \cdot \ln(\text{NASDST}) + 0,0017 \cdot (\text{DELNEKMECK81})^2$$

Vsi regresijski koeficienti v enačbi so značilni ($p < 0,0001$). Koeficient korelacije je $R = 0,76$; delež pojasnjene variance je $R^2 = 0,57$. Standardizirani regresijski koeficienti, ki nam povedo relativni pomen posamezne spremenljivke v modelu, so:

- $G75 = 0,5199$ (Gozdnatost [%] leta 1975 v okolici s polmerom 0,5 km).
- $\ln(\text{NASDST}) = 0,4026$ (Zračna razdalja od piksla do najbližjega naselja [m]).
- $(\text{DELNEKMECK81})^2 = 0,1332$ (Delež dopolnilnih kmetij v KO v letu 1981 [%]).

Če v enačbo namesto preteklih vrednosti G75 in DELNEKMECK81 vstavimo današnje izhodiščne vrednosti G95 (spremenljivka je izpeljana analogno kot G75) in DELNEKMECK91, dobimo prognostično karto zaraščanja za obdobje 1995 – 2015 (slika 4).




		Leto 1995					
		Gozd	Gmišče	Opušteni travnik	Negozd		
Naselje (0)	Voda (9)	Stalno gozd (8)	Krčitev + zarašč. (7)	Krčitev + opušč. (6)	Izkrčeno (5)	Gozd	Leto 1975
		Zl. travnik (1)	V opuščanju (2)	Stalno negozd (1)	Negozd		
		Stara 1995					
Settlement	Water	Permanent forest	Cleared & afforested	Cleared & abandoned	Cleared	Forest	Stara 1995
		Already afforested	In the process of afforestation	In the process of abandonment	Permanent nonforest	Nonforest	

Slika 4: Karta zaraščanja v obdobju 1975 – 1995

Figure 4: Afforestation map for the period 1975 – 1995

Na sliki 5 smo za površine, ki so bile v letu 1995 še nezarasle, prikazali predvideno stopnjo zaraščенosti v letu 2015. Opozoriti je treba, da ima zaradi načina izračuna odvisne spremenljivke INDZAR (povprečna stopnja zaraščенosti v okolici s premerom 1 km) tudi prognostična karta zaraščanja vsebinsko gledano ločljivost enako 1 km, čeprav je piksel na karti velik le 25 m.



Stopnja zaraščanja (*Afforestation intensity*):

0 %

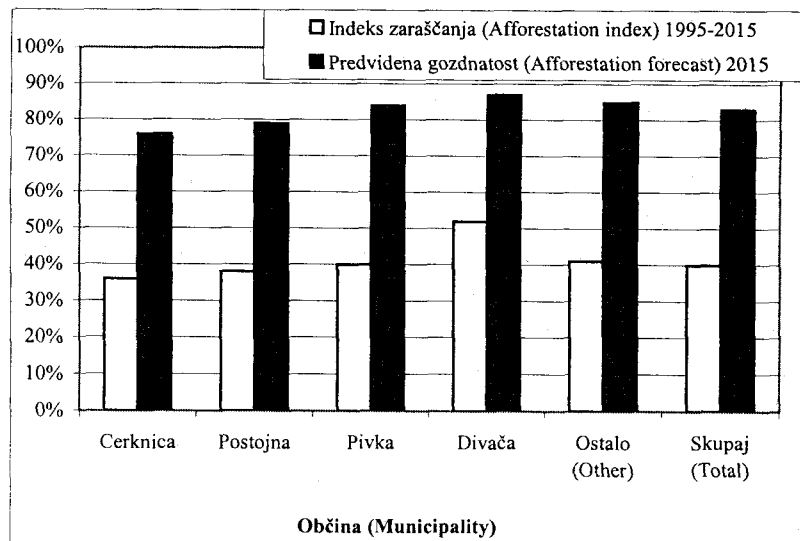
100 %

Gozd 1995, jezero
Forest 1995, lake

Slika 5: Predvidena stopnja zaraščanja v obdobju 1995 – 2015

Figure 5: *Afforestation forecast for the period 1995 – 2015*

Povprečna stopnja napovedanega zaraščanja kmetijskih površin v obdobju 1995 – 2015 za celotno raziskovalno območje znaša 40 % in je skoraj enaka stopnji preteklega zaraščanja (37 %). To je skladno s predpostavko modela zaraščanja, ki napoveduje prihodnje zaraščanje na osnovi dosedanjih trendov. Gozdnatost naj bi se povečala s 75 % leta 1995 na 83 % leta 2015. Bolj zanimiva je raznolika porazdelitev zaraščanja. Pregled po občinah kaže (slika 6), da naj bi bilo zaraščanje najintenzivnejše v občini Divača (52 %); v občinah Postojna, Cerknica in Pivka pa naj bi se zaraslo 36 % do 41 % kmetijskih površin. Občina Divača naj bi tako imela leta 2015 kar 87 % gozdnatost. Najmanj gozdnata občina naj bi bila Cerknica, vendar bi naj bila njena gozdnatost še vedno 76-odstotna.



Slika 6: Porazdelitev napovedanega zaraščanja v letih 1995 – 2015 po občinah

Figure 6: Distribution of the forecasted afforestation (1995 – 2015) for the four municipalities

4 RAZPRAVA DISCUSSION

Metoda, ki smo jo uporabili za kartiranje gozdnega roba na satelitskem posnetku Landsat TM, združuje v uporaben postopek tri ločene tehnike: nenadzorovano klasifikacijo, strojno učenje in klasifikacijo na podlagi logičnih pravil. S tako kombinacijo smo omogočili bistveno poenostavitev dela in dosegli večjo podrobnost kartiranja v primerjavi z referenčnim virom, t.j. s slovensko bazo *CORINE Land Cover*. Racionalizacija je predvsem v tem, da smo: (1) močno skrajšali fazo poimenovanja pri nenadzorovani klasifikaciji; (2) s strojnim učenjem zelo hitro pripravili serijo odločitvenih pravil za drugo fazo klasifikacije. Izboljšanje podrobnosti je vidno v povečanju prostorske ločljivosti karte na 0,25 ha (4 slikovne piksele); v primerjavi s slovensko bazo CLC, kjer najmanjša površina kartiranja znaša 20 ha, je povečanje ločljivosti 80-kratno. Pozicijska napaka gozdnega roba na karti v 50 % ne presega 14 m (približno pol piksla), v

povprečju pa znaša 26,6 m (en piksel). Če kot kriterij vzamemo grafično natančnost 0,3 mm, potem taka pozicijska napaka dovoljuje uporabo karte v merilu 1 : 50.000. Dosežena tematska točnost na ravni vseh štirih kartiranih razredov pokrovnosti (negozd / opuščeni travnik / grmišče / gozd) znaša 82 % (67 % po statistiki Kappa). Na ravni dveh agregiranih razredov – (negozd + opuščeni travnik + grmišče) / gozd – se poveča na 91 % (81 % Kappa). Ta razlika gre predvsem na račun napak pri kartiranju grmišč in opuščenih travnikov. Vzroke za manj uspešno kartiranje teh dveh razredov pokrovnosti vidimo v njihovi slabši določljivosti tako na satelitski sliki kot tudi na aeroposnetkih in v rahli razliki definicij med učnimi ter kontrolnimi podatki. Dosežena točnost kartiranja je vseeno na enaki ali boljši ravni kot pri primerljivih raziskavah drugih avtorjev in to pri precej manjši porabi časa za kartiranje (npr. BODMER 1993, REUTHER *et al.* 1996, SLAYMAKER *et al.* 1996, VOGELMANN / SOHL / HOWARD 1998). Tudi neposredna primerjava metode klasifikacije z odločitvenimi drevesi s konvencionalnimi metodami klasifikacije, ki sta jo izvedla FRIEDL in BRODLEY (1997), potrjuje prednost odločitvenih dreves tako glede točnosti kot glede porabe časa za kartiranje. Vzrokov posebne uporabnosti odločitvenih dreves na področju daljinskega zaznavanja je več; glavne prednosti so: enostavnost in jasnost; odločitvena drevesa ne predpostavljajo določene porazdelitve podatkov in so zato precej neobčutljiva na šum v podatkih ali na nelinearne zveze med spremenljivkami; obvladajo tako zvezne kot diskretne spremenljivke, zato je v postopek klasifikacije mogoče vključiti tudi dodatne informacije v tematskih GIS-slojih. Informacijsko vsebino in s tem točnost ter podrobnost gozdnih kart je namreč s kombiniranjem GIS in daljinsko zaznanih podatkov mogoče občutno povečati (HOČEVAR 1996).

Pomembno zaslugo za hitro kartiranje ima tudi razpoložljivost baze CLC, zaradi česar smo prihranili veliko časa pri zbiranju učnih podatkov. Podoben pristop – t.j. uporabo že obstoječe tematske karte kot učnega podatka za klasifikacijo satelitske slike – so s pridom uporabili tudi drugi avtorji (BUCHA 1997 os. komunikacija, STOMS *et al.* 1998). Sprejemljiva točnost karte pri precej večji prostorski ločljivosti v primerjavi s prostorsko posplošenimi učnimi podatki ni presenetljiva. Ta pojav so opazili tudi drugi avtorji in je poznan kot "čistilni učinek" oziroma *clean-up effect* (MICHIE / CAMACHO 1994). Učinek nastopi zaradi strojnega učenja, ki prepoznava neznačilne primere v učnih podatkih (le-ti so nastali zaradi napak fotointerpretacije in digitalizacije v teku projekta *CORINE Land Cover*) ter jih izloči. Čistilni učinek je bil v našem primeru še okrepljen

zaradi posegov interpretatorja, ki je popravljaj vsebino odločitvenih dreves v skladu s svojim poznavanjem razmer v študijskem območju.

Glavna pomanjkljivost predstavljene metode kartiranja gozda je, da je kakovost rezultatov precej odvisna od dobrega poznavanja raziskovalnega območja in od razpoložljivosti ažurnih velikoprostorskih učnih podatkov. Glede slednjega ocenjujemo, da bi pri sedanji stopnji zaraščanja baza CLC iz leta 1996 lahko služila kot učna podlaga do leta 2010. V EU in v Sloveniji že potekajo aktivnosti za ažuriranje baze CLC na podlagi slik satelita Landsat 7 ETM+ iz leta 2001. V primeru ponovnega kartiranja bi v veliki meri lahko uporabili obstoječi odločitveni drevesi, ki bi ju prilagodili novejšim satelitskim podatkom.

5 SUMMARY

The first aim of the study was to streamline a method of forest cover change detection for the period from 1975 to 1995 at the regional level based on the Landsat TM satellite data and on existing maps and GIS layers. The second aim was to make a trend – based, spatially explicit forecast of the forest cover change for the next 20 years.

Forest cover change was identified using map differencing based on forest cover maps of 1975 and 1995. The 1975 map was acquired by using the scanned forestry layer of a legacy topographical map scaled 1:50.000. The 1995 map was prepared by numeric classification of ortho-rectified Landsat TM image. The classification consisted of two successive stages – unsupervised classification of a Landsat TM multispectral image, followed by rule – based reclassification using ancillary GIS data. Next, the non-forest thematic classes were aggregated and finally the map was spatially generalized using sieve filtering. Machine learning was used in some steps of classification in order to streamline the procedure as much as possible.

The accuracy assessment of the 1995 map was based on an independent control sample, which was acquired by photo-interpretation of aerial imagery. We assessed both the thematic accuracy (using confusion matrix and Kappa statistics) as well as forest border delineation accuracy (using epsilon band method). Overall thematic accuracy of the 1995

map was 82 % (Kappa 67 %). When nomenclature was aggregated from 4 to 2 classes (forest / non-forest), the accuracy increased to 91 % (Kappa 81 %). Assessment of delineation accuracy shows that 50 % of the mapped forest border was within 14 m from the true location. The average departure from the true location was 26,6 m.

Between 1975 and 1995 forest cover increased by 21.080 ha (from 62 % to 75 %), which corresponds to a loss of 37 % of agricultural land. Average yearly rate of spontaneous afforestation was 1,9 %.

A statistical regression model was made to explain the spontaneous afforestation in the previous 20-year period using various GIS layers as independent variables. The model was subsequently used to make a trend-based forecast of spontaneous afforestation in the period 1995-2015. The afforestation intensity was illustrated using the INDZAR index, which is defined as a percentage ratio between the newly afforested area and the original agricultural area in the local neighborhood. The model explains 57 % of the INDZAR variability. The most informative explanatory variables are, respectively: the original forest percentage, proximity to settlements, and proximity to original forest border. In the next 20 years, the most heavily afforested municipality will be Divača (52 % afforestation of the present agricultural land), followed by Postojna, Cerknica, and Pivka (36 % to 41%).

6 VIRI

REFERENCES

- AL-GARNI, A. M., 1994. Remote sensing geology and expert systems.- 1994 ASPRS/ACSM annual convention & exposition technical papers, Reno, Nevada, April 25-28, s. 47-59.
- BELWARD, A. S., 1995. The IGBP – DIS global 1 km land cover project: remote sensing in action.- V: Proc. 21th Annual Conf. of the Remote Sensing Society, Southampton, UK, s. 1099-1106.
- BLAKEMORE, M., 1984. Generalization and error in spatial databases.- Cartographica 21: 131-139.

- BODMER, H. C., 1993. Untersuchung zur forstlichen Bestandeskartierung mit Hilfe von Satellitbildern.- Dissertation, Professur für Forsteinrichtung und Waldwachstum der ETH Zürich, 160 s.
- BREIMAN, L. / FRIEDMAN, J. H. / OLSHEN, R. A. / STONE, C. J., 1984. Classification and Regression Trees.- Wadsworth, Belmont.
- BRUZZONE, L. / CONESE, C. / MASELLI, F. / ROLI, F., 1997. Multisource classification of complex rural areas by statistical and neural-network approaches.- Photogram. Engin. Remote. Sens. 63, 5: 523-533.
- CESTNIK, B. / KONONENKO, I. / BRATKO, I., 1987. ASSISTANT 86: A knowledge elicitation tool for sophisticated users.- V: BRATKO, I. / LAVRAČ, N. (ur.), Progress in Machine Learning, Wilmslow, Sigma Press, s. 31-45.
- CHRISMAN, N., 1982. A theory of cartographic error and its measurement in digital data bases.- V: Proceedings of the Fifth International Symposium on Computer-Assisted Cartograph (Auto Carto 5), Falls Church, Virginia, ASPRS and ACSM, s. 159-168.
- CIVCO, D., 1993. Artificial neural network for land-cover classification an mapping.- Int. J. Geograph. Inform. Systems 7, 2: 173-186.
- CONGALTON, R. G., 1991. A review of assessing the accuracy of classification of remotely sensed data.- Remote Sens. Environ. 37: 35-46.
- CUNDER T., 1998. Zaraščanje kmetijskih zemljišč v slovenskem alpskem svetu.- V: GOSAR, A. (ur.), Sonaravni razvoj v slovenskih Alpah in sosedstvu, Ljubljana, Filozofska fakulteta, 49 s.
- ČERNE, F. / TURK, I., 1999. Nacionalni program varstva okolja. Ur. l. RS št. 83/99.
- DeFRIES, R. S. / HANSEN M. / TOWNSHEND, J. R. G. / SOHLBERG, R., 1998. Global land cover classification at 8 km spatial resolution: the use of training data derived from Landsat imagery in decision tree classifiers.- Int. J. Remote Sensing 19, 16: 3141-3168.
- DUNN, R. / HARRISON, A. R. / WHITE, J. C., 1990. Positional accuracy and measurement error in digital databases of land use: an empirical study.- Int. J. Geograp. Inform. Systems 4, 4: 385-398.
- EC, 1997. Posnetek Landsat TM 191/28, 26 julij 1995, za project CORINE Land Cover.- European Commission, PHARE program.
- FRIEDL, M. A. / BRODLEY, C. E., 1997. Decision tree classification of land cover from remotely sensed data.- Remote Sens. Environ. 61: 399-409.

- GABROVEC M., 1996. Solar radiation and the diverse relief of Slovenia.- Geografski zbornik 36: 47-68.
- GOLOB, S., 1998, Dokumenti vseevropskega procesa o varovanju gozdov v Evropi.- Ljubljana, Ministrstvo za kmetijstvo, gozdarstvo in prehrano, 63 str.
- GONG, P., 1996. Integrated analysis of spatial data from multiple sources: using evidential reasoning and artificial neural network techniques for geological mapping.- Photogram. Engin. Remote. Sens. 62, 5: 513-523.
- GURS, 1995a. Digitalni model reliefa s horizontalno ločljivostjo 100 x 100 m.- Geodetska uprava RS.
- GURS, 1995b. Skenirana topografska karta 1 : 50.000, izdana 1981.- Geodetska uprava RS.
- HOČEVAR, M. / KOBLER, A. / CUNDER, T., 2001. Prostorsko modeliranje potencialnega zaraščanja kmetijskih zemljišč v Sloveniji v GIS okolju.- Rokopis. Gozdarski inštitut Slovenije. 30 s.
- HOČEVAR, M. / KOBLER, A. / VRŠČAJ, B. / POLJAK, M. / KUŠAR, G., 2001. CORINE karta rabe tal in pokrovnosti Slovenije – fotointerpretacija in rezultati.- Zaključno poročilo, Gozdarski inštitut Slovenije, 83 s.
- HOČEVAR, M., 1993. Daljinsko pridobivanje podatkov v gozdarstvu.- Ljubljana, Biotehniška fakulteta, Oddelek za gozdarstvo, 105 s.
- HOČEVAR, M., 1996. Uporaba satelitske detekcije v gozdarstvu.- V: MATKO, D. (ur.), Uporaba vesoljskih tehnologij, Didakta, s. 280-301.
- HUANG, X. / JENSEN, J. R., 1997. A machine-learning approach to automated knowledge-base building for remote sensing image analysis with GIS data.- Photogram. Engin. Remote. Sens. 63, 10: 1185-1194.
- HUANG, X., 1998. The use of machine learning in remote sensing and GIS: a comparison of symbolic learning and neural networks.- APRS – RTI Annual Conf. Technical Papers, s. 981-991.
- KOBLER, A., 2001. Sprejemljivost zaraščanja kot funkcija kakovosti kulturne krajine: prostorski model.- Magistrska naloga, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, 187 s.
- LILLESAND, T. M. / KIEFER, R. W., 1994. Remote sensing and image interpretation (3rd Edition).- John Wiley & Sons, 747 s.
- MCCORMICK N., 1999. Satellite-based forest mapping using the SILVICS software.- User Manual. Space Applications Institute, Joint Research Centre, Ispra.

- MICHIE, D. / CAMACHO, R., 1994. Building symbolic representations of intuitive real-time skills from performance data.- V: FURUKAWA, K. / MICHIE, D. / MUGGLETON, S. (ur.), *Machine Intelligence 13*, Oxford University Press, s. 385-418.
- NLR (National Aerospace Laboratory), 1997. Ortorektificirani posnetek satelita Landsat TM, 191/28, 26 julij 1995, za projekt CORINE Land Cover Slovenia.
- PERKO, D. / OROŽEN-ADAMIČ, M. (ur.), 1998. *Slovenija – pokrajine in ljudje*.- Ljubljana, Mladinska knjiga, 735 s.
- QUINLAN, J. R., 1986. Induction of decision trees.- *Machine Learning* 5, 3: 239-266.
- QUINLAN, J. R., 1993. *C4.5: Programs for Machine Learning*.- San Mateo, CA, Morgan Kaufmann. 302 s.
- REUTHER, M. / HÄUSLER, T. / AKGÖZ, E. / HOFFMANN, K. / STÄTTER, R., 1996. *Waldzustandserfassung im Fichtelgebirge und Erzgebirge mit Hilfe der Fernerkundung*.- Uni. München, Forstliche Forschungsberichte 160.
- RICHARDS, J. A., 1993. *Remote sensing digital image analysis: an introduction* (2nd Edition).- Springer Verlag, 339 s.
- SKIDMORE, A. K. / TURNER, B. J. / BRINKHOF, W. / KNOWLES, E., 1997. Performance of a neural network: mapping forests using GIS and remotely sensed data.- *Photogram. Engin. Remote. Sens.* 63, 5: 501-514.
- SLAYMAKER, D. M. / JONES, K. M. L. / GRIFFIN, C. R. / FINN, J. Z., 1996. Mapping deciduous forests in Southern New England using aerial videography and hyperclustered multi-temporal Landsat TM imagery.- V: SCOTT, J. M. / TEAR, T. H. / DAVIS, F. W. (ur.). *Gap Analysis: A Landscape Approach to Biodiversity Planning*, American Society of Photogrammetry and Remote Sensing, s. 87-101.
- SMITH J. A. / LIN, T. L. / RANSON, K. J., 1980. The Lambertian assumption and Landsat data.- *Photogram. Engin. Remote. Sens.* 46, 9: 1183-1189.
- STOMS, D. M. / BUENO, M. J. / DAVIS, F. W. / CASSIDY, K. M. / DRIESE, K. L. / KAGAN, J. S., 1998. Map-guided classification of regional land cover with multi-temporal AVHRR data.- *Photogram. Engin. Remote. Sens.* 64, 8.
- VARLYGUIN, D. / WRIGHT, R. / GOETZ, S. J. / PRINCE, S. D., 2001. Advances in land cover classification for applications research: a case study from the mid-Atlantic RESAC.- *American Society for Photogrammetry and Remote Sensing (ASPRS) Conference Proceedings*, St. Louis, MO, www.geog.umd.edu/resac.

- VOGELMANN, J. E. / SOHL, T. / HOWARD, S. M., 1998. Regional characterisation of land cover using multiple sources of data.- *Photogram. Engin. Remote. Sens.* 64, 1: 45-57.
- WILSON, P. A., 1997. Rule-based clasification of water in Landat MSS images using the variance filter.- *Photogram. Engin. Remote. Sens.* 63, 5: 485-491.
- ZEFF, I. S. / MERRY, C. J., 1993. Thematic mapper data for forest resource allocation.- *Photogram. Engin. Remote. Sens.* 59, 1: 93-99.

ZAHVALA

ACKNOWLEDGEMENTS

Članek povzema del magistrske naloge (KOBLER 2001), ki se je nanašala na razvoj metode za kartiranje gozda s pomočjo satelitske slike in se je vključevala v raziskovalna projekta "Razvoj večnamenskega gozdarskega informacijskega sistema" ter "Uporaba multispektralnih satelitskih posnetkov visoke ločljivosti, GIS in izgradnja DSS (*Decision Support System*) za modeliranje v gozdarstvu". Projekta sta pod vodstvom prof. dr. Milana Hočevarja potekala na Gozdarskem inštitutu Slovenije, financirali pa sta ju Ministrstvo za šolstvo, znanost in šport ter Ministrstvo za kmetijstvo, gozdarstvo in prehrano. Za nasvete in pomoč se zahvaljujemo doc. dr. Sašu Džeroskemu in univ. dipl. geog. Tomažu Cundru.