Postupci pri fotointerpretaciji za potrebe šumarstva

Ferderber, Luka

Undergraduate thesis / Završni rad

2016

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Forestry / Sveučilište u Zagrebu, Šumarski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:108:697022

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

University of Zagreb Faculty of Forestry and Wood Technology

zir.nsk.hr

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZAGREBU
ŠUMARSKI FAKULTET
ŠUMARSKI ODSJEK

PREDDIPLOMSKI STUDIJ
ŠUMARSTVO

LUKA FERDERBER

POSTUPCI PRI FOTOINTERPRETACIJI ZA POTREBE ŠUMARSTVA

Procedures in the photo-interpretation for forestry use

ZAVRŠNI RAD

ZAGREB, (RUJAN, 2016.)

PODACI O ZAVRŠNOM RADU

Zavod:	Zavod za izmjeru i uređivanje šuma
Predmet:	Daljinska istraživanja i GIS u šumarstvu
Mentor:	dr.sc Ante Seletković
Asistent – znanstveni novak:	
Student:	Luka Ferderber
JMBAG:	0068214562
Akad. godina:	2015/2016.
Mjesto, datum obrane:	Šumarski fakultet, 23. rujna 2016. godine
Sadržaj rada:	Stranica: 20 Slika: 10 Tablica: 1 Navoda literature: 9

Sažetak: Fotointerpretacija je postupak odnosno metoda analize fotosnimke (aerofotosnimke) s ciljem prepoznavanja različitih sastavnica slike i utvrđivanja njihove povezanosti i značenja. Fotointerpretacija je djelatnost pri kojoj se analiziraju, dešifriraju tj. čitaju fotosnimci ili samo njihovi dijelovi, radi dobivanja vizualnih informacija i mjerenja šumskih sastojina na aerosnimkama.Postupci pri analizi slike su; otkrivanje, prepoznavanje, delineacija, mjerenje, dedukcija i usporedba, klasifikacija i kodiranje (obrojčavanje). U ovom završnom radu opisani su i prikazani svi postupci pri fotointerpretaciji aerosnimaka za potrebe šumarstva.

SADRŽAJ

1. UVOD....1
2. Definicija fotointerpretacije....2
3. Sastavnice slike....2
3.1. Boja i ton....2
3.2. Veličina....3
3.3. Oblik....4
3.4. Sjena....5
3.5. Položaj....6
3.6. Tekstura....6
3.7. Uzorak....6
3.8. Grupiranje - pripadnost....7
4. Analiza slike....8
4.1. Otkrivanje....8
4.2. Prepoznavanje....9
4.3. Delineacija....9
4.4. Mjerenje....10
4.5. Dedukcija....10
4.6. Klasifikacija....11
4.7. Kodiranje (obrojčavanje)....12
5. Metode pri fotointerpretaciji....13
5.1. Mjerna fotointerpretacija....13
5.1.1. Broj stabala....13
5.1.2. Visina stabla....14
5.1.3. Dimenzije krošanja i prsni promjer....14
5.1.4. Mjerenje površina....15
5.2. Vizualna fotointerpretacija....15
5.2.1. Vrsta drveća....15
5.3. Digitalne metode fotointerpretacije aerosnimaka....18
6. ZAKLJUČAK....19
7. LITERATURA....20

1. UVOD

Daljinska istraživanja (engl. remote sensing) danas su nezaobilazna metoda u raznim znanstvenim područjima, a dobiveni rezultati zahvaljujući razvoju računalnih tehnologija nalaze široku primjenu u različitim disciplinama. Riječ je o metodi prikupljanja i interpretaciji informacija o udaljenim objektima bez fizičkog dodira s objektom. Uključuje sve aktivnosti od snimanja, procesiranja, analiziranja, interpretacije, do dobivanja informacija iz podataka prikupljenih tim istraživanjem (Frančula i dr., 1994). Podaci se dobivaju iz velike udaljenosti (od nekoliko stotina do nekoliko tisuća kilometara) instrumentima postavljenim u zračne ili svemirske letjelice.

Cilj daljinskih istraživanja je brzo i ekonomično dobivanje preciznih informacija o relativno velikim područjima. Sustavnim ponavljanjem snimanja moguće je pratiti i registrirati dnevne, sezonske i godišnje promjene neke pojave. Objekt daljinskih istraživanja su svi elementi Zemljine površine i atmosfere u vidnom polju senzora (Oluić, 2001).

Prva snimanja Zemlje iz zraka napravljena su sredinom 19. stoljeća. Godine 1858. Tournachon iz balona radi prve snimke za analizu gradskog područja Pariza. Masovna primjena zračnih snimaka i fotointerpretacije započela je u Prvome, a nastavljena je u Drugom svjetskom ratu. Revoluciju u daljinskim istraživanjima predstavlja početak snimanja iz svemira. Glavnina istraživanja u Hrvatskoj provedena su na području analogne fotogrametrije tj. fotogrametrijskom izmjerom i fotointerpretacijom stereoparova klasičnih analognih aerosnimaka uz pomoć analognih aeroinstrumenata. U Hrvatskoj primjena daljinskih istraživanja zaostaje za razvijenim zemljama suvremenog svijeta. Razlozi su višestruki,a među glavnima su: visoka cijena opreme i aerosnimaka, zahtjevan uredski rad koji iziskuje klasične fotogrametrijske metode, nedovoljno stručnih kadrova, nepovjerenje u nove metode te dobiveni rezultati koji često nisu udovoljavali svim potrebama prakse (Kušan 1996,Balenović idr. 2010). Primjena u znanstvene i stručne svrhe neorganizirana je i rascjepkana po pojedinim ustanovama što otežava značajniji napredak. Najznačajnija institucija koja potiče, unapređuje, koordinira i organizira primjenu daljinskih istraživanja je Znanstveno vijeće za daljinska istraživanja i fotointrepretaciju pri HAZU-u.

2. Definicija fotointerpretacije

Glavni cilj aerofotogrametrije u šumarstvu je mjerenje interpretativnih pojedinosti šumskih sastojina ili šumskih zemljišta. Fotogrametrijskom izmjerom i fotointerpretacijom aerosnimaka moguće je prikupiti informacije potrebne za pravilno gospodarenje šumskim sastojinama. Fotointerpretacija je djelatnost pri kojoj se analiziraju, dešifriraju tj. čitaju fotosnimci ili samo njihovi dijelovi, radi dobivanja vizualnih informacija i mjerenja šumskih sastojina na aerosnimkama. Takvu djelatnost obavljaju stručnjaci: geolozi, šumari, gografi, pedolozi i dr. Pri tome oni polaze od čitanja i sadržaja snimaka da bi sintezom došli do nekih kompleksnih zaključaka.

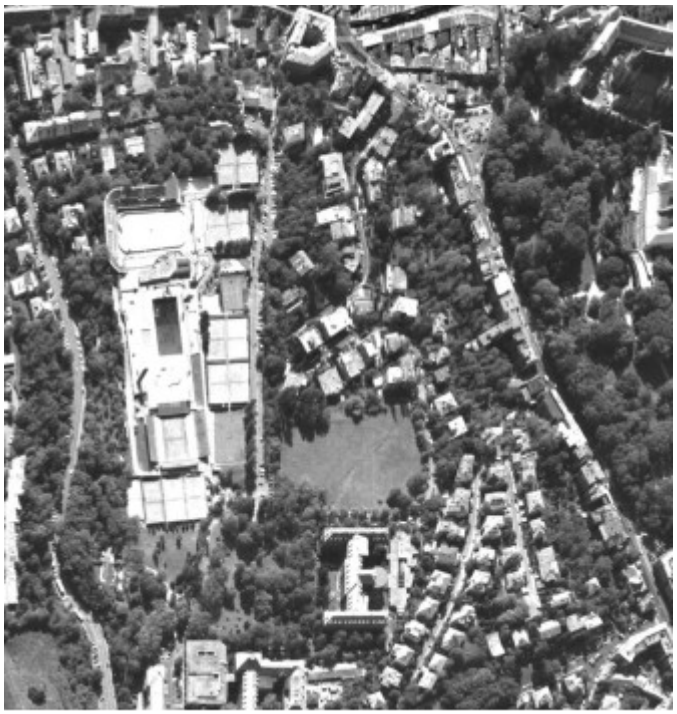
3. Sastavnice slike

Fotointerpretacija predstavlja postupak analize slike na temelju sljedećih sastavnica slike:

- boja – ton,
- velicina,
- oblik,
- sjena,
- tekstura,
- uzorak,
- položaj objekta u prostoru,
- grupiranje.

3.1. Boja i ton

Ton predstavlja relativnu svjetlinu ili boju elemenata na fotografiji. To je, možda, jedan od najosnovniji elemenata interpretacije. Vegetacija, voda i tlo odražavaju i reflektiraju različite vrijednosti elektromagnetskog zračenja (energije) u vidljivom (plavom, zelenom, crvenom), te bližem infracrvenom dijelu elektromagnetskog spektra. Na temelju toga interpretator kreira spektralni zapis za vegetaciju, vodu, tlo... Takvi spektralni zapisi omogućuju raspoznavanje različitih objekata na crno bijelim ili fotografijama u boji. Kada govorimo o crno bijelim fotografijama radi se o tonu (nijanse od crne do bijele), a kod fotografije u boji naravno o boji.



Slika 1. Prikaz boje i tona aerosnimke

3.2. Veličina

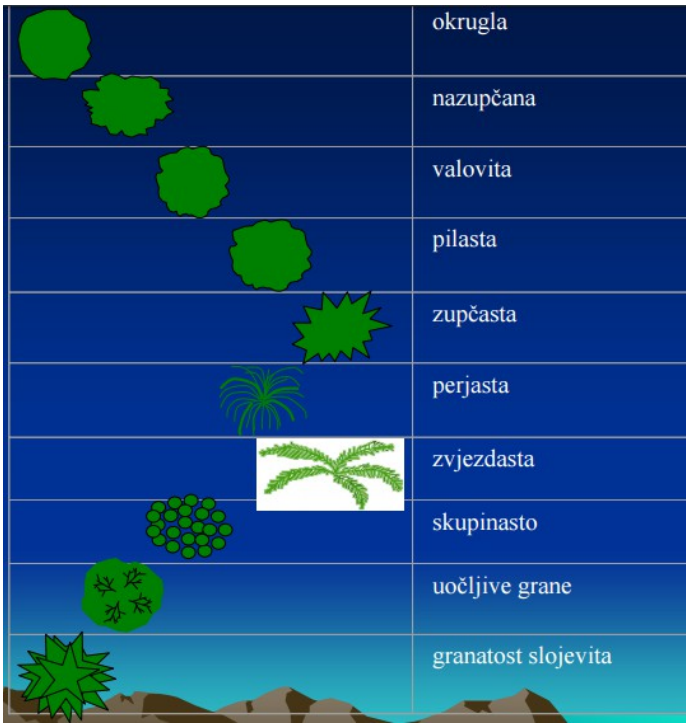
Veličina objekta je jedan od najvažnijih elemenata pri razlikovanju karakteristika objekta pri interpretaciji. Najćešće se mjere dužina, širina i opseg objekta, a da bi se to moglo uspješno odraditi potrebno je znati i odrediti mjerilo snimaka. Kod veličine, kao sastavnice slike, veliku ulogu ima prepoznavanje poznatih vrijednosti veličine npr. nogometni stadion, bazen, kako bi na temelju tih poznatih veličina mogli usporedbom odrediti i veličinu ili dimenziju drugog (nepoznatog) objekta.



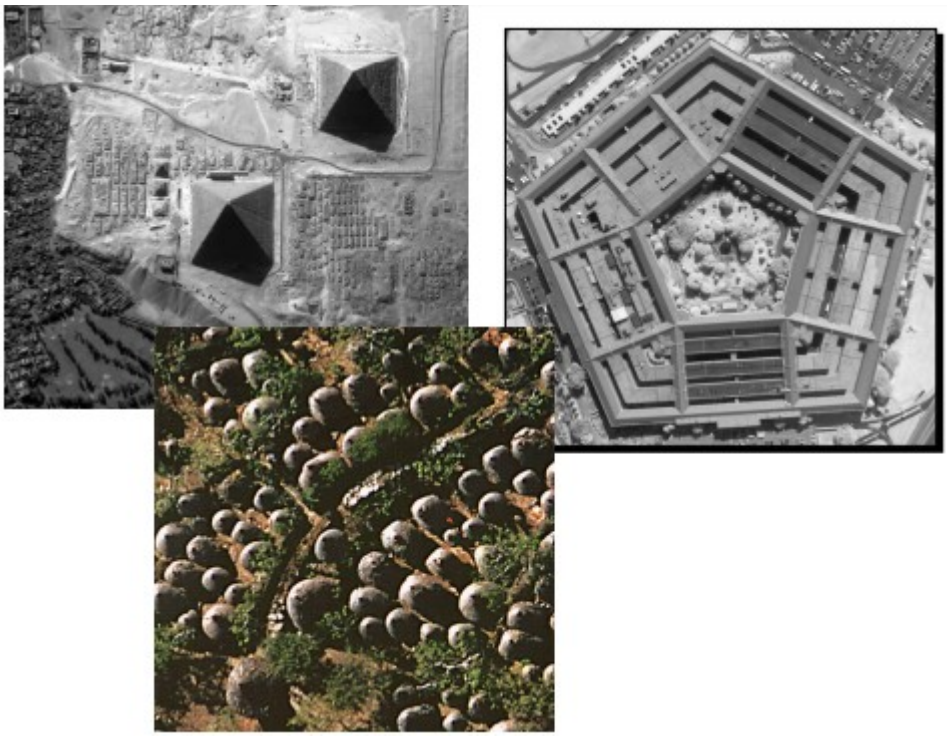
Slika 2. Prikaz veličine objekata aerosnimke

3.3. Oblik

Pravilni geometrijski oblici su obično pokazatelji ljudske prisutnosti i korištenja. Neki objekti mogu se identificirati gotovo isključivo na osnovi njihovih oblika. Postoji beskonačan broj jedinstveno oblikovanih prirodnih i umjetnih objekata u svijetu. Uglavnom je lakše prepoznati i identificirati umjetno nastali objekt (zgrada, prometnica, zrakoplov, automobil...) od prirodnog. Kod prirodnih objekata ti su oblici suptilniji.



Slika 3. Oblici krošanja



Slika 4. Prikaz različitih oblika aerosnimke

3.4. Sjena

Gotovo svi podaci skupljeni metodama daljinskih istraživanja su unutar 2-3 sata od sunčevog podneva, kako bi se izbjegle sjene od objekata na snimkama koje otežavaju interpretaciju. Međutim u nekim slučajevima upravo sjena je ključan faktor kod identifikacije nekog objekta.



Slika 5. Sjena

3.5. Položaj

Odnosi se na topografski ili zemljopisni položaj. Dvije su osnovne metode za dobivanje točne lokacije u obliku koordinata. 1) tradicionalne metode izmjere ili GPS mjerenja, ili 2) metode daljinskih istraživanja.

3.6. Tekstura

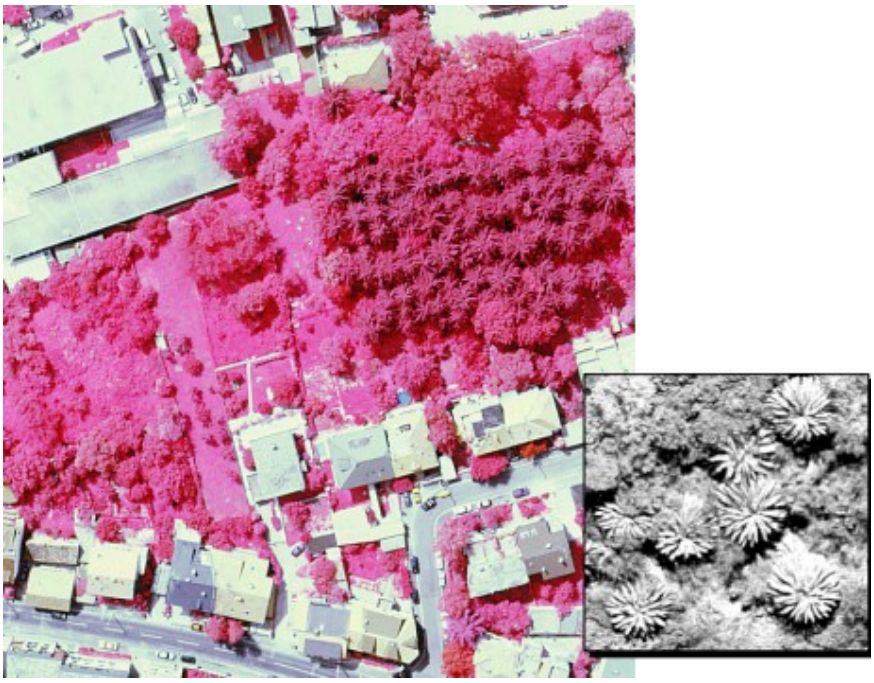
Tekstura je odnos tona, veličine, oblika i sijena na vrlo malo detalja. Definira se kao "karakterističan položaj i raspored ponavljanja tona ili boje u slici". Pridjevi koji se često koriste za opisivanje teksture su glatke (ujednačena, homogena), srednje i grubo (gruba, heterogena). Važno je zapamtiti da je tekstura je odnos tona, veličine, oblika i sijena.



Slika 6. Prikaz teksture šume

3.7. Uzorak

Uzorak predstavlja prostorni raspored objekata u krajoliku. Predmeti mogu biti raspoređeni nasumično ili sustavno. Oni mogu biti prirodni i umjetni. Tipični pridjevi koji se koriste u opisivanju uzorka su: slučajni, sistematski, okrugli, ovalan, linearni, pravokutni i zakrivljen drugi.



Slika 7. Prostorni raspored objekata krajolika

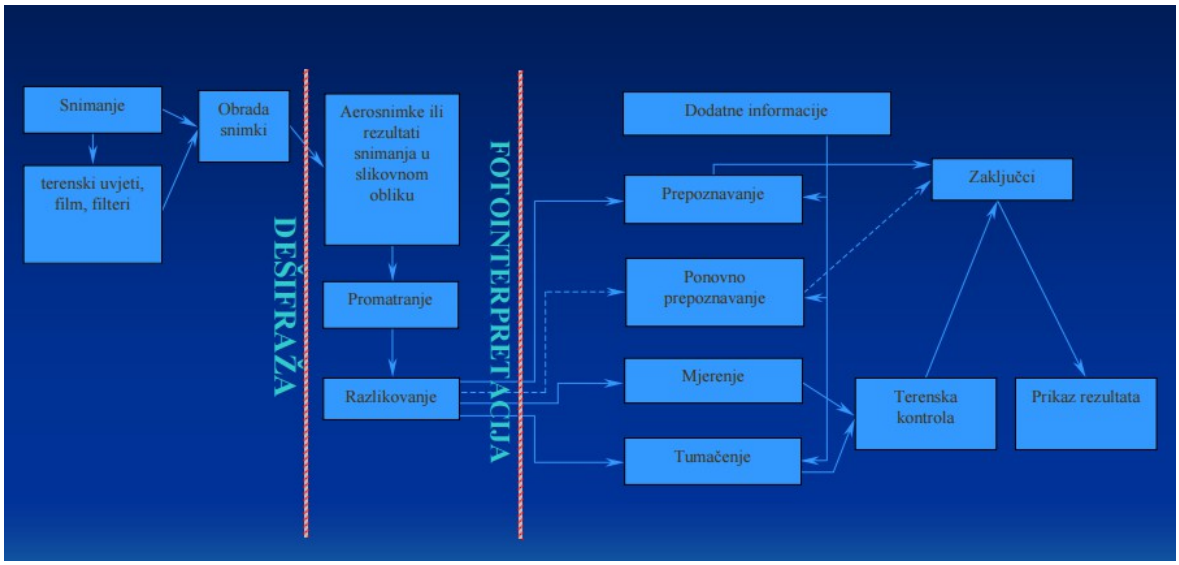
3.8. Grupiranje - pripadnost

Neki objekti uvijek se mogu naći u suradnji s drugim objektima. Samo okruženje objekta može dati uvid što to ustvari predstavlja.

4. Analiza slike

U sljedećem poglavlju daju se definicije sljedećih postupaka koji se koriste prilikom analiza slike:

- otkrivanje,
- prepoznavanje,
- delineacija,
- mjerenje,
- dedukcija i usporedba,
- klasifikacija,
- kodiranje (obrojcavanje).



Slika 8. Područje fotointerpretacije

4.1. Otkrivanje

Prvi postupak pri fotointerpretaciji je otkrivanje ili detekcija nama nekih poznatih objekata. Jedan od najvažnijih faktora za pepoznavanje stimulansa snimaka je vid fotointerpretatora. Opažanje je proces koji je iznad fizioloških svojstava oka. Interpretator pronalazi slikovne detalje na aerosnimkama tražanjem uz pomoć svog vida. Uspjeh fotointerpretatora u pronalaženju objekata uvelike je zavisan kako o njegovoj mentalnoj dispoziciji tako i oštrini njegova vida.

4.2. Prepoznavanje

Prepoznavanje ili identifikacija uključuje mjerenje različitih ciljeva u slika kako bi dobili korisne prostorne informacije o njima. Ciljevi mogu biti značajka točka, linija ili površina, to znači da oni mogu imati bilo koji oblik. npr. nogometno igralište, avion na pisti, prostranstva vode ili šuma. Što je veća prostorna/spektralna razlučivost slike, više detalja možemo izvući iz slike. Sposobnost interpretatora za identifikaciju objekata, koji su se preslikali na aerosnimkama, je u očitom odnosu za poznavanje oblika i dimenzija sličnih ili identičnih objekata. Sposobnost za identifikaciju nekog objekta zavisit će o tome koliko je puta interpretator vidio taj i identificirao ispravno slične objekte. Instrument koji relativno ima najveće značenje je stereoskop koji nam omogućuje trodimenzionalnu predodžbu slikovnog sadržaja aerosnimke. Stereoskop sa lećama omogućuje simulaciju gledanja na daljinu, tj omogućuje opažaču da istovremeno promatra dva snimka istog objekta koji je registriran s dva različita snimališta u prostoru da na taj način percipira trodimenzionalnu predodžbu tog objekta.



Slika 9. Identifikacija ciljeva

4.3. Delineacija

Delineacija ili izlučivanje sastojina na odjele i odsjeke, koje prethodi izmjeri sastojina, zahtjevan je i dugotrajan posaopri uređajnoj inventuri šuma. To je posebno izraženo za ona šumska područja za koja ne postoji prethodna gospdarska podjela. Stoga je

fotogrametrijsko izlučivanje sastojina vizualnom interpretacijom na aerosnimkama, koje se obavljalo pomoću stereoinstrumenata, bilo predmet prvih istraživanja.

U Hrvatskoj je s kartiranjem za potrebe uređivanja šuma pomoću aerosnimaka započeo Tomašegović (1956) izradom i korištenjem fotoplanova. Kasnije je areofotosnimke koristio i za procjenu izlučenih površina (Tomašegović 1961). Benko (1993) je izradio delineiranu topografsku kartu s ucrtanim izlučenim sastojinama i njezinim dijelovima, koristeći vizualnu interpretaciju infracrvenih kolornih (ICK) aerosnimaka mjerila 1:10000. Izlučio je obrasle i neobrasle površine (ceste, kanali), poljoprivredne kulture, plješine i vlažnije tlo. Šumom obrasle površine dalje je izlučio prema dobi (starije, mlađe) i sklopljenosti (potpuna, nepotpuna).

Pernar (1997) je izlučivala sastojine prema vidljivim razlikama na ICK aerosnimkama i to: vrsti drveća, omjeru smjese, sklopljenosti sastojina, veličini krošanja, stupnju oštećenosti, pojavi matičnog supstrata itd. Klobučar (2004) istražuje mogućnost korištenja digitalnog ortofota, izrađenog od crno-bijelih aerosnimaka približnog mjerila 1:20000, u izlučivanju sastojina prema sklopu. Uspoređujući tako dobivene granice i površine odsjeka s onim dobivenim izravno na terenu, zaključuje da su utvrđene razlike u većini odsjeka prihvatljive, uz opasku da izlučivanje pomoću digitalnog ortofota može poslužiti samo kao uredska podloga za terenski rad u izlučivanju sastojina.

4.4. Mjerenje

Mjerenja u fotointerpretaciji se sastoje od vizualnog određivanja deimenzija i oblika nekog objekta. Mjerni pribori su: linerani mjerni pribor, pribor za mjerenje površina, pribor za mjerenje visina i pribor za kartiranje.

4.5. Dedukcija

Deduktivna metoda je sustavna primjena deduktivnog načina zaključivanja u kjem se od općih sudova izvode posebni i pojedinačni zaključci. Dedukcija uvijek pretpostavlja poznavanje općih znanja na temelju kojih se spoznaje ono posebno ili pojedinačno. Najvažniji elementi deduktivne metode su postupci metoda analize, sinteze, apstrakcije, generalizacije i specijalizacije.

Prilikom dedukcije, čak više nego prilikom prepoznavanja i identifikacije, moraju se uvažavati različite razine stručnosti. To često nije tako lako, budući da treba pažljivo

razlikovati pitanja koja se tiču općeg znanja koje posjeduju obrazovane osobe, pitanja od zajedničkog znanja između određene skupine znanstvenika i pitanja koja pripadaju specifičnim znanjima određene znanosti ili znanstvenika. Također, potrebno je imati na umu razlike između pitanja koji su dio općih procesa i pitanja od lokalnog znanja, odnosno proces generalizacije koji se pri tome može javiti i dovesti do pogrešne dedukcije.

4.6. Klasifikacija

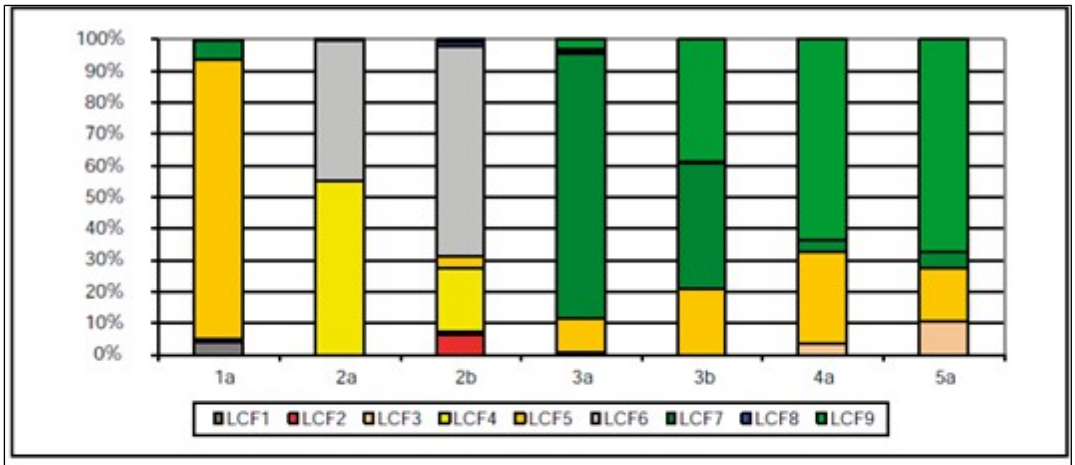
Klasifikaciji aerosnimke pristupamo nakon delineacije gdje smo temeljem vizualne interpretacije izlučili određen broj poligona koje smo svrstali u klase. Klasifikacija je završni korak u procesu fotointerpretacije, a slijedi ju terenska provjera koja daje posljednju riječ i konačnu odluku. Dakle, klasifikacija predstavlja završni korak koja može i često bi trebala biti učinjena kao priprema za završni rad na terenu. Najjednostavnija klasifikacija pri foto interpretaciji je klasifikacija analiziranih značajki prema njihovoj vjerojatnoj pouzdanosti i to postupcima:

- povlačenja linija (visoka pouzdanost) i
- isprekidana linija (relativno niska pouzdanost).

Pri tome se čini važan korak, od jednostavne usporedbe susjednih pojedinačnih značajki pokušava se uspostaviti, odnosno razvrstati njihov identitet prema pojedinim skupinama. Metoda se temelji na prethodnim procesima i njena pouzdanost u velikoj mjeri ovisi o razini stručnosti istraživača.

4.7. Kodiranje (obrojčavanje)

Kodiranje je postupak gdje svakoj pojedinoj klasi dodjeljujemo njeno kodno ime.



Skupne kategorije		Klase tijeka promjena (LCF)	
Oznaka	Naziv skupne kategorije	Kod	Naziv klase
1a	Čovjekom utjecane površine	LCF1	Gospodarenje urbanim prostorom
2a	Oranice i trajni nasadi	LCF2	Širenje naseljenih područja
2b	Heterogene poljoprivredne površine	LCF3	Širenje gospodarskih i infrastrukturnih površina
3a	Šume i šikare	LCF4	Promjene unutar poljoprivrednoga korištenja
3b	Grmolika i travna vegetacija	LCF5	Povećanje poljoprivrednih površina
4a	Močvare	LCF6	Napuštanje poljoprivrednih površina
5a	Vode	LCF7	Gospodarenje šumama
		LCF8	Izgradnja vodenih tijela i vodno gospodarstvo
		LCF9	Promjene pokrova zemljišta uzrokovane prirodnim procesima

Grafikon 1. Primjer kodiranja aerosnimke nakon izvršene klasifikacije

5. Metode pri fotointerpretaciji

5.1. Mjerna fotointerpretacija

Uspješna fotointerpretacija ovisit će o prirodi objekta snimanja, kvaliteti fotografija ili snimaka (prostorna, radiometrijska i spektralna rezolucija) te utreniranosti o iskustvu istraživača, odnosno interpretatora. Precizna procjena strukturnih elemenata sastojina ovisi o sljedećim čimbenicima:

- strukturi šumskih sastojina (gustoći sastojine, omjeru smjese vrste drveća, fenologiji i drugim sastojinama),
- topografiji terena (visina i nagib),
- sustavu kamere (geomterijska, radiometrijska i spektralna rezolucija),
- uvjetima snimanja (kut položaja sunca i atmosferski uvjeti),
- parametri leta (odnos baze snimanja i visine snimanja , mjerilo snimanja),
- postupku interpretacije (stereo instrument i vještine interpretatora).

Dio strukturnih elemenata moguće je direktno interpretirati, mjeriti ili procjenjivati na aerosnimkama, poput vrste drveća, broja stabala, visine stabla, dimenzije krošnje i sklopa, dok se drugi dio elemenata dobiva indirektno temeljem uspostavljenih odnosa (regresijskih jednadžbi) između fotogrametrijskih i terestrički izmjerenih veličina (prsni promjer, temeljnica ili volumen).

5.1.1. Broj stabala

Fotogrametrijski određen broj stabala predstavlja broj vidljivih krošanja na aerosnimkama, a proces brojanja stabala na aerosnimkama uspješnije se izvodi stereoskopskim promatranjem u stereomodelu, nego na pojedinačnim snimcima. Primjenom digitalnih aerosnimaka visokih prostornih rezolucija, koje se u odnosu na analogne aerosnimke odlikuju i boljom radiometrijskom rezolucijom, smanjuje se uobičajeno podcjenjivanje broja stabala pri fotogrametrijskoj izmjeri. Time je omogućena bolja razlučivost pri fotointerpretaciji, odnosno moguće je registrirati dio „slijepljenih“ krošanja te dio zasjenjenih stabala uslijed povećane vidljivosti područja pod sjenama. Dodatnim terenskim

uzorkovanjem i postavljanjem korekcijskih ploha te izradom regresijskih jednadžbi, moguće je otklonuti problem podstojne etaže.

Preciznost određivanja broja stabala ovisi o strukturnim i drugim karakteristikama sastojina (starost, vrsta drveća, prostorni raspored stabala, gustoća, uzgojni oblik i način gospodarenja), karakteristikama aerosnimaka te kao i u prethodnom slučaju, iskustvu fotointerpretatora.

5.1.2. Visina stabla

Na aerosnimakama moguće je odrediti visinu stabla na sljedeće načine:

- izmjerom dužine sjene na pojedinačnim aerosnimkama,
- izmjerom radijalnog izmještanja na pojedinačnim aerosnimkama,
- mjerenjem razlike stereoskopskih paralaksi u optičkom stereomodelu na stereoparovima primjenom stereoskopa s mehaničkim stereomikrometrom,
- stereoskopskim mjerenjem na aerosnimkama s analognim, analitičkim ili digitalnim stereoinstrumentima (digitalnim fotogrametrijskim stanicama).

Osnovni neostatak izmjere visine stabla pomoću stereoskopa i analognih stereoinstrumenata u gustim sklopljenim sastojinama u kojima s ne vidi tlo pokraj stavla, otklonjen je primjenom analitičkih i digitalnih stereoinstrumenata.

5.1.3. Dimenzije krošanja i prsni promjer

Promjer krošnje, površinu projekcije krošnje i dužinu krošnje, odnosno dužinu osvijetljenog dijela krošnje moguće je mjeriti na aerosnimkama, a s obzirom na pogled odozgo, aerosnimke u načelu pružaju veće mogućnosti za ispravno mjerenje krošanja u usporedbi s uobičajenim terestičkim radovima. Izmjera dimenzija krošanja na aerofototaksaciji ima posebno značenje te se na temelju mjerenja dimenzija krošanja određuje sklop, a posrednim putem uz pomoć regresijskih jednadžbi i prsni promjer stabla.

Dimenzije krošanja se na analognim aerosnimkama mogu mjeriti pomoću klinastog razmjrnika, skale uzoraka i mreže točaka. Digitalnom fotogrametrijom, dimezije krošanja mogu se jednostavno mjeriti manualnim ili automatskim metodama na pojedinačnim aerosnimcima, odnosno na digitalnom ortofotu (DOF) ili u stereomodelu aerosnimaka na

digitalnoj fotogrametrijskoj stanici. Automatske metode delineacije kršanja, predmet su brojnih istaživanja.

Budući da se prsni promjer stabla ne može direktno izmjeriti na aerosnimkama, pri procjeni prsnog promjera stabla u fotogrametriji koristi se ovisnost između prsnog promjera i promjera krošnje. Najčešće se za procjenu prsnog promjera koriste regresijski modeli s jednom fotogrametrijski izmjerenom nezavisnom varijablom, promjerom krošanja ili regresijski modeli s dvije nezavisne varijable, promjerom krošanja i visinom stabla.

5.1.4. Mjerenje površina

Način mjerenja površina uz pomoć aerosnimaka ovisi o obliku tih površina. Jednostavan je način mjerenja površina koji imaju pravokutan oblik pomoću lineralnih mjerenja i jednostavnih formula za površine. Površine nepravilna oblika na vertikalnim aerosnimkama koji se mogu odrediti polarnim ili nitnim planimetrom. U šumarstvu se također koriste matematičko-statistički principi opažanja mreže točaka. Takav se planimetar sastoji od kvadratne ili pravoutne mreže ncrtane na prozirnoj foliji, tako da se u svakom od tih polja nalazi sistemski raspoređen skup točaka. Mreža točaka se stavlja na snimak na kojem se vrše matematičko-statistička opažanja pa se zbrajaju točke koje padaju na pojedini tip objekata. Svaka izbrojana točka ima određenu površinsku vrijednost koja je zavisna o mjerilu snimaka i razmaku točaka na foliji.

5.2. Vizualna fotointerpretacija

5.2.1. Vrsta drveća

Na raspoznavanju slikovnih značajki pojednih vrsta drveća, odnosno njihovih krošanja temelji se vizualna interpretacija vrsta drveća. Prvenstveno se temelji na izgledu krošnje koja je definirana s dva osnovna kriterija, općim izgledom i bojom krošnje. Opći izgled, odnosno oblik krošnje opisan je s vanjskom konturom (izgledom krošnje u tlocrtu i nacrtu), strukturom (načinom granjanja) i teksturom krošnje (najfinijim detaljima, smještajem i oblikom lista, veličinom i smještajem jednogodišnjih izbojaka i slično). Boja krošnje određena je svjetlinom, tonom i zasićenjem, a sve nabrojane značajke izgleda krošnje karakteristične su za pojedine vrste drveća. Ukoliko postoje izrađeni fotointerpreacijski ključevi sa svim nabrojanim značajkama izgleda krošnje karakterističnim za određene vrste drveća, olakšana je vizualna iinterpretacija (Pernar, 1994). Uspjeh vizualne interpretacije

vrste drveća ovisit će o karakteristikama pojednih vrsta drveća, položaju stabla u sastojini i na aerosnimkama, karakteristikama aerosnimaka (mjerilo, prostorna, spektralna i radiometrijska rezolucija), sezoni snimanja te o već spomenutom iskustvu interpretatora.

U odnosu na automatske metode, vizualna interpretacija smatra se relativno sporom i subjektivnom metodom. Iako automatizirane ili automatske metode interpretacije aerosnimaka pokazuju obećavajuće rezultate prilikom primjene u određivanju položaja stabla i delineaciji krošanja, osobito u čistim sastojinama, u pogledu preciznosti raspoznavanja pojedinih vrsta drveća, vizualna interpretacija još uvijek ima prednost pred automatskim ili automatiziranim metodama interpretacije.

5.2.1.1. Fotointerpretacijski ključ

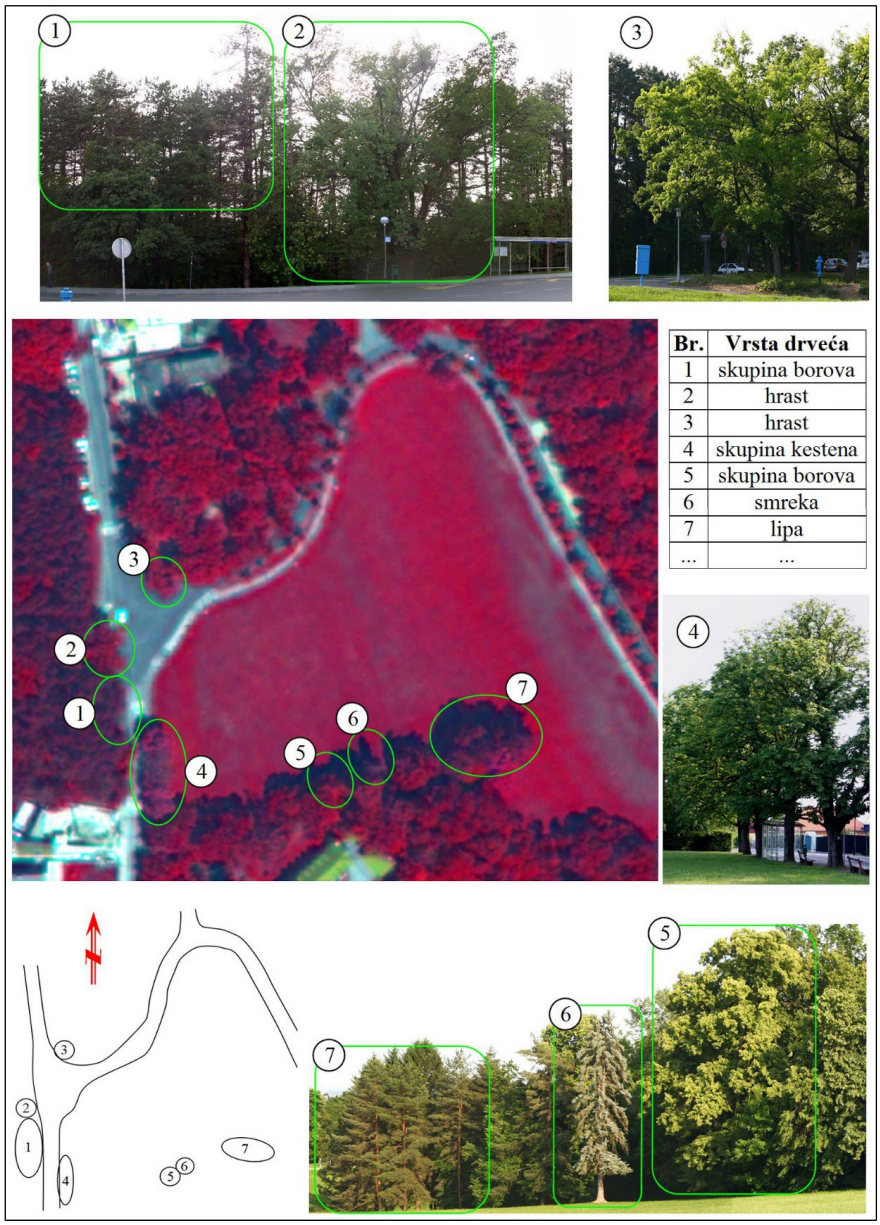
U svrhu prikupljanja podataka za izradu fotointerpretacijskoga ključa, izvršioci interpretacije su u vremenu određenom za snimanje na području koje pokriva satelitska snimka, obavili potrebne terenske radove.

Inventarizacija oštećenosti šuma pomoću aerosnimki temelji se na ustanovljavanju stupnja oštećenosti pojedinačnih stabala (krošanja), koja se vide na aerosnimkama. Veza između stanja na terenu i na aerosnimkama, odnosno način preslikavanja pojedinih stupnjeva oštećenosti za svaku interpretiranu vrstu drveća, uspostavlja se pomoću pažljivo izrađenog fotointerpretacijskog ključa. Fotointerpretacijski ključ se definira pomoću utvrđenih pravila preslikavanja. U njemu se opisno, crtežom ili fotografijom daju karakteristike izgleda pojedinih vrsta drveća i stupnjeva oštećenosti na aerosnimkama. Kod toga treba definirati izgled krošanja obzirom na dva kriterija: opći izgled i boju.

Opći izgled se može najbolje poistovjetiti s oblikom krošnje, a njega opisujemo: vanjskom konturom, strukturom i teksturom. Pod vanjskom konturom podrazumijevamo elemente koji izgrađuju izgled krošnje u tlocrtu i nacrtu. Ona je vrlo važna za klasifikaciju oštećenosti, jer su patološke promjene ovdje najuočljivije. Struktura krošnje ovisi najviše o načinu grananja stabla i karakteristična je za svaku pojedinu vrstu. Teksturom opisujemo najfinije detalje u izgledu krošnje koji najviše ovise o morfološkim karakteristikama vrste.

Boja krošnje se može okarakterizirati: svjetlinom, tonom i zasićenjem. Ona je proizvod od krošnje reflektiranog svjetla. Veličina remisije u određenom spektralnom području ovisi o lisnim pigmentima, strukturi staničja i o gustoći krošnje, odnosno udjelu ostalih dijelova

stabla (izbojci, grane, dijelovi debla) u reflektiranju svjetla. Svi ti elementi karakteristični su za pojedine vrste drveća i stadije oštećenosti. Boja je važan pokazatelj za klasifikaciju oštećenosti, ali ne i isključivi. Balans pojedinih boja na ICK snimkama razvijanjem nije moguće egzaktno uspostaviti, što znači da se isti objekti, od serije do serije filma, od slike do slike, mogu preslikati u nešto različitim nijansama. Ako je to slučaj, onda se ispravna klasifikacija provodi na osnovi elemenata općeg izgleda krošnje. To je i razlog što se za interpretaciju oštećenosti pojedinih stabala zahtijevaju aerosnimke krupnog mjerila. Uz pomoć izrađenih fotointerpretacijskih ključeva, procijenjeno je zdravstveno stanje pojedinih krošanja i svrstavanje u određene stupnjeve oštećenosti. Radi mogućnosti uspoređivanja s terestričkim inventurama oštećenosti šuma, stupanj oštećenosti određen je prema kriterijima propisanim za terestričku inventuru. Na osnovi predodžbe o načinu preslikavanja pojedinih vrsta drveća i stupnjeva oštećenosti definiran je fotointerpretacijski ključ za glavne vrste drveća (Slika 10).



Slika 10. Fotointerpretacijiski ključ

5.3. Digitalne metode fotointerpretacije aerosnimaka

Digitalna obrada i analiza aerosnimaka razvija se sa pojavom digitalnog bilježenja podataka daljinskih istraživanja i razvoja računala. Kada su podaci dostupni u digitalnom formatu daljinskih istraživanja, digitalna obrada i analiza može se provesti pomoću računala, takva obrada može se koristiti kako bi se poboljšala podatke kao uvod u vizualnu interpretaciju.

Digitalna analiza zahtijeva specijaliziranu, a često i skupu opremu. Računala okolina je podložnija rješavanju kompleksnih slika, nekoliko ili mnogo kanala sa različitim

datumima. U tom smislu, digitalna analiza je korisna za istovremenu analizu mnogih spektralna područja i može obraditi velike skupove podataka mnogo brže nego ljudski tumač. Priručnik interpretacija je subjektivan proces, što znači da će rezultati variraju s različitim prevoditeljima. Digitalna analiza temelji se na manipulaciju digitalnih brojeva u računalu, a time je više objektivna.

Važno je napomenuti da vizualne i digitalne analize daljinskih istraživanja slike se međusobno ne isključuju. Obje metode imaju svoje dobre strane. U većini slučajeva, kombinacija obje metode se obično koristi kada se analizira slika. U stvari, konačnu odluku o korisnosti i važnosti informacija na kraju procesa analize, i dalje mora biti od strane ljudi.

6. ZAKLJUČAK

Fotointerpretacija je djelatnost pri kojoj se analiziraju, dešifriraju tj. čitaju fotosnimci ili samo njihovi dijelovi, radi dobivanja vizualnih informacija i mjerenja šumskih sastojina na aerosnimkama.

Fotointerpretacija predstavlja postupak analize slike na temelju sastavnica slike (boja – ton, velicina, oblik, sjena, tekstura, uzorak, položaj objekta u prostoru, grupiranje)

Za kvalitetnu analizu slike važno je poznavati i pravilno upotrebljavati postupke pri fotointerpretaciji; otkrivanje, prepoznavanje, delineacija, mjerenje, dedukcija i usporedba, klasifikacija.

.

7. LITERATURA

1. Balenović, I., 2011: Mogućnost primjene digitalnih aerofotogrametrijskih snimaka različitih prostornih rezolucija u uređivanju šuma, Disertacija, 166 str., Zagreb.

2. Tomašegović, Z., 1986: Fotogrametrija i fotointerpretacija u šumarstvu, Šumarski fakultet Sveučilišta u Zagrebu, 157 str., Zagreb.
3. Donassy, V. i dr. (1983): Daljinska istraživanja u geoznanostima, Jugoslavenska akademija znanosti i umjetnosti, Zagreb.
4. Frančula, N. i dr. (1994): Primjena daljinskih istraživanja u kartografiji, Geodetski list 48 (3), 265-276.
5. Oluić, M. (2001): Snimanje i istraživanje Zemlje iz svemira: sateliti-senzori-primjena, Hrvatska akademija znanosti i umjetnosti i Geosat, Zagreb
6. Benko, M., 1993: Procjena taksacijskih elemenata sastojina na infracrvenim kolornim aerosnimkama, Glas. šum. pokuse, 29:199-274, Zagreb.
7. Pernar, R.: Predavanja iz predmeta „Daljinska istraživanja i GIS u šumarstvu“
8. Kalafadžić, Z., V, Kušan, 1987.: Primjena ICK aerosnimaka u šumarstvu, Šumarski list 111 (1- 2): 61 – 66.
9. Balenović, I., Benko, M. 2011: Prošlost, sadašnjost i budućnost primjene metoda daljinskih istraživanja pri inventuri šuma u Hrvatskoj, Šum. List posebni broj, 272-281, Zagreb.
10. Benko, M., 1993: Procjena taksacijskih elemenata sastojina na infracrvenim kolornim aerosnimkama, Glas. Šum. Pokuse, 29: 199-274, Zagreb.
11. DGU, 2004: 301D150 Product Specification Digital Terrain Model CRONO GIP, Državna geodetska uprava, 117 str., Zagreb.
12. Fotointerpretacija, Manual of photographic interprettion american society of photogrammetry, Vuk Karadžić, 1973, 11-908, Beograd.
13. Seletković A, Pernar R, Jazbec A, Ančić M, Točnost klasifikacije satelitske snimke visoke prostorne rezolucije ikonos za potrebe šumarstva, Šumarski list, br. 9-10, 393-404, Zagreb
14. www.wikipedia.com
15. www.nrcan.gc.ca
16. www.nature.berkley.edu