

**UNIVERZITET U BANJOJ LUCI  
ELEKTROTEHNIČKI FAKULTET**

**Snježana Momić**

**VIZUELNA OBILJEŽJA VAZDUŠNIH  
I SATELITSKIH SLIKA**

**Diplomski rad**

**Banja Luka, jun 2009.**

Tema:

**VIZUELNA OBILJEŽJA VAZDUŠNIH  
I SATELITSKIH SLIKA**

**Ključne riječi:**  
**Vazdušne i satelitske slike**  
**Deskriptor teksture**  
**Klasifikacija uzorka**

Komisija:

**prof. dr Đemal Kolonić, predsjednik**  
**prof. dr Zdenka Babić, mentor**  
**mr Vladimir Risojević, član**

**Kandidat:**  
**Snježana Momić**

UNIVERZITET U BANJOJ LUCI  
ELEKTROTEHNIČKI FAKULTET  
KATEDRA ZA OPŠTU ELEKTROTEHNIKU

Predmet: **DIGITALNA OBRADA SLIKE**

Tema: **VIZUELNA OBILJEŽJA VAZDUŠNIH I  
SATELITSKIH SLIKA**

Zadatak: Dati pregled vizuelnih obilježja koja se koriste kod vazdušnih i satelitskih slika. Ispitati mogućnost primjene vizuelnih obilježja pri pretraživanju baza vazdušnih i satelitskih slika. Ispitati mogućnost primjene vizuelnih obilježja za automatsku klasifikaciju vazdušnih i satelitskih slika.

Mentor: prof. dr Zdenka Babić

Kandidat: Snježana Momić (26/01)

Banja Luka, jun 2009.

# Sadržaj

<b>1. UVOD .....</b>	<b>1</b>
1.1 Daljinsko snimanje.....	1
1.2 Spektralna analiza podataka.....	4
<b>2. SISTEM ZA PREPOZNAVANJE OBLJEŽJA NA VAZDUŠNIM I SATELITSKIM SLIKAMA .....</b>	<b>9</b>
2.1 Izdvajanje obilježja .....	9
2.2 Treniranje (učenje).....	9
2.3 Labelisanje .....	11
2.4 Procjena tačnosti (validacija).....	11
2.5 O predloženom rješenju .....	11
<b>3. DESKRIPTOR TEKSTURE .....</b>	<b>12</b>
3.1 Vizuelna obilježja slika.....	12
3.2 Obilježje teksture .....	13
3.3 Gaborov deskriptor teksture.....	13
3.3.1 Gaborov filter i banka filtera.....	13
3.3.2 Reprezentacija obilježja teksture .....	16
3.3.3 Invarijantnost na rotaciju .....	16
<b>4. NEURONSKE MREŽE .....</b>	<b>19</b>
4.1 Definicija i pojam neuronske mreže .....	19
4.2 Arhitekture neuronskih mreža.....	20
4.3 Algoritmi učenja .....	22
4.4 Nenadgledano učenje .....	22
4.4.1 Kompetitivno učenje.....	23
4.4.2 SOM mreža .....	25
4.5 LVQ mreža.....	33
<b>5. IMPLEMENTACIJA I EVALUACIJA PERFORMANSI SISTEMA ZA SEGMENTACIJU VAZDUŠNIH SLIKA .....</b>	<b>36</b>
5.1 Implementacija.....	36
5.1.1 Baza blokova slika .....	36
5.1.2 „Najbliži susjed“ klasifikacija.....	38
5.1.3 SOM mapa i klasifikacija na principu većinskog glasanja .....	40
5.1.4 LVQ .....	41
5.2 Testiranje sistema za semantičku segmentaciju.....	44
<b>6. ZAKLJUČAK .....</b>	<b>59</b>
<b>7. LITERATURA.....</b>	<b>60</b>
<b>8. DODATAK.....</b>	<b>62</b>
<b>Uz rad je priložen CD.</b>	

# 1. UVOD

Sve je počelo 1957. godine lansiranjem SPUTNIKA I, prvog Zemljinog vještačkog satelita [1]. Rani sateliti su bili opremljeni instrumentima (senzorima) za mjerena u bliskoj okolini Zemlje. Nastajanjem i primjenom sofisticiranijih instrumenata preko satelita počinju osmatranja vanjskog svemira, a 1972. godine lansiranjem satelita koji je nazvan LANDSAT fokus istraživanja se ponovo vraća posmatranju Zemlje i od tada satelitske kamere i senzori sistematski snimaju i kartiraju (eng. mapping) Zemlju tj. njenu atmosferu, hidrosferu, kriosferu i biosferu. Snimanje se vrši pomoću tehnologije poznate pod nazivom daljinsko snimanje (eng. Remote sensing). Dakle, daljinsko snimanje [2] je nauka o mjerenu karakteristika od interesa sa određene udaljenosti. Pod daljinskim snimanjem se podrazumijeva snimanje Zemlje pomoću instrumenata pozicioniranih u avio ili svemirskim letjelicama.

## 1.1 Daljinsko snimanje

Prve fotografije iz vazduha pojavile su se sredinom 19. vijeka (snimak Bostona iz balona sa toplim vazduhom sa visine od cca 400 m, 1860.), što odmah nalazi vojnu primjenu - snimka položaja južnjačkih trupa oko Richmonda u Virginiji koju su formirali pripadnici sjevernjačke vojske za vrijeme građanskog rata u Sjedinjenim Američkim Državama. Naročito zanimljive su snimke iz vazduha, snimljene u San Francisku nakon zemljotresa i to pomoću niza od 17 papirnatih zmajeva koji su bili pričvršćeni za čamce usidrene u zaljevu. Prije 1960 godine foto kamera je bila najšire upotrebljavani sistem daljinskog snimanja iako su infracrveni i radarski sistemi razvijani i upotrebljavani za vrijeme drugog svjetskog rata.

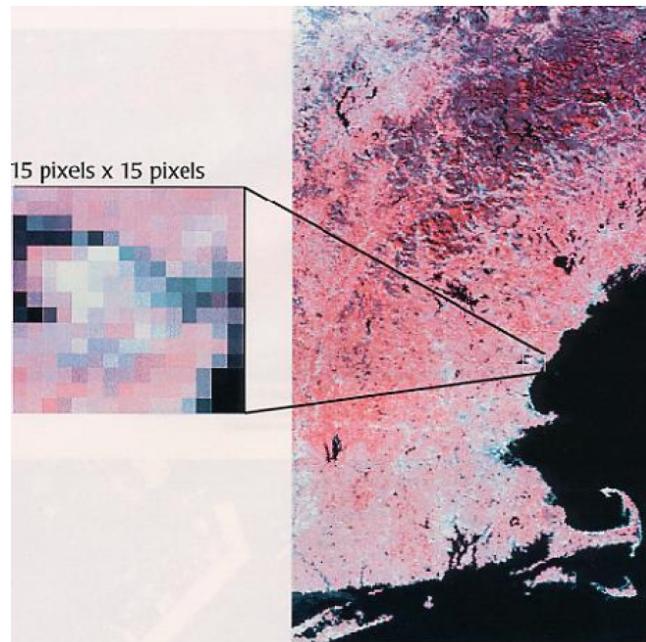
Svemirsko posmatranje počinje lansiranjem satelita TIROS I (Television Infrared Observation Satellite). TIROS - serija satelita je prethodnik današnjih NOAA (National Oceanic and Atmospheric Administration) satelita za praćenje vremenskih prilika koji kruže u polarnim orbitama. Prvi satelit za posmatranje Zemlje bio je ERTS (Earth Resource Technology Satellite) kojeg je lansirala NASA 1972. godine. Ovaj je satelit kasnije nazvan LANDSAT I i bio je prvi iz serije LANDSAT satelita projektovanih za iscrtavanje izgleda Zemljine površine. Naučno-tehničke i tehnološke inovacije te praćenje i analiza satelitskih snimaka u posljednjih trideset godina iz temelja su promjenile naše gledanje na Planet. Godinama je ta tehnologija bila vezana uz vojsku i nacionalnu sigurnost te uz razvojne programe u visoko-naučnim ili komercijalnim institucijama SAD. Međutim, širenje satelitske tehnologije i na druge zemlje, te nagli razvoj kompjuterske tehnologije omogućili su cijelom svijetu korišćenje ove tehnologije. Jedna od najpoznatijih snimaka Zemlje iz svemira je tzv."Plavi mramor" (eng. "Blue marble") snimljena iz svemirskog broda APOLLO 17 na putu za Mjesec u decembru 1972.godine.

Danas postoji niz sistema za akviziciju podataka u cilju dobijanja podataka pomoću daljnog snimanja. Mjerena kao što su mjerena uzvišenja na površini dobijena altimetrom (visinomjerom) i mjerena reflektovanog zračenja od Zemlje na raznim

talasnim dužinama dobijeni radiometrom, spektrometrom ili spektro-radiometrom su sva predstavljena kao slike. Broj spektralnih opsega koje koriste instrumenti za akviziciju može da varira od jednog (panhromatski – opseg vidljive svjetlosti) do nekoliko stotina (multispektralni/hiperspektralni instrumenti). Mjerenja mogu da se vrše iz aviona i satelita, pri čemu slike iz aviona mogu pružiti više detalja, dok satelitske slike pružaju manje detalja, ali prekrivaju veću površinu.

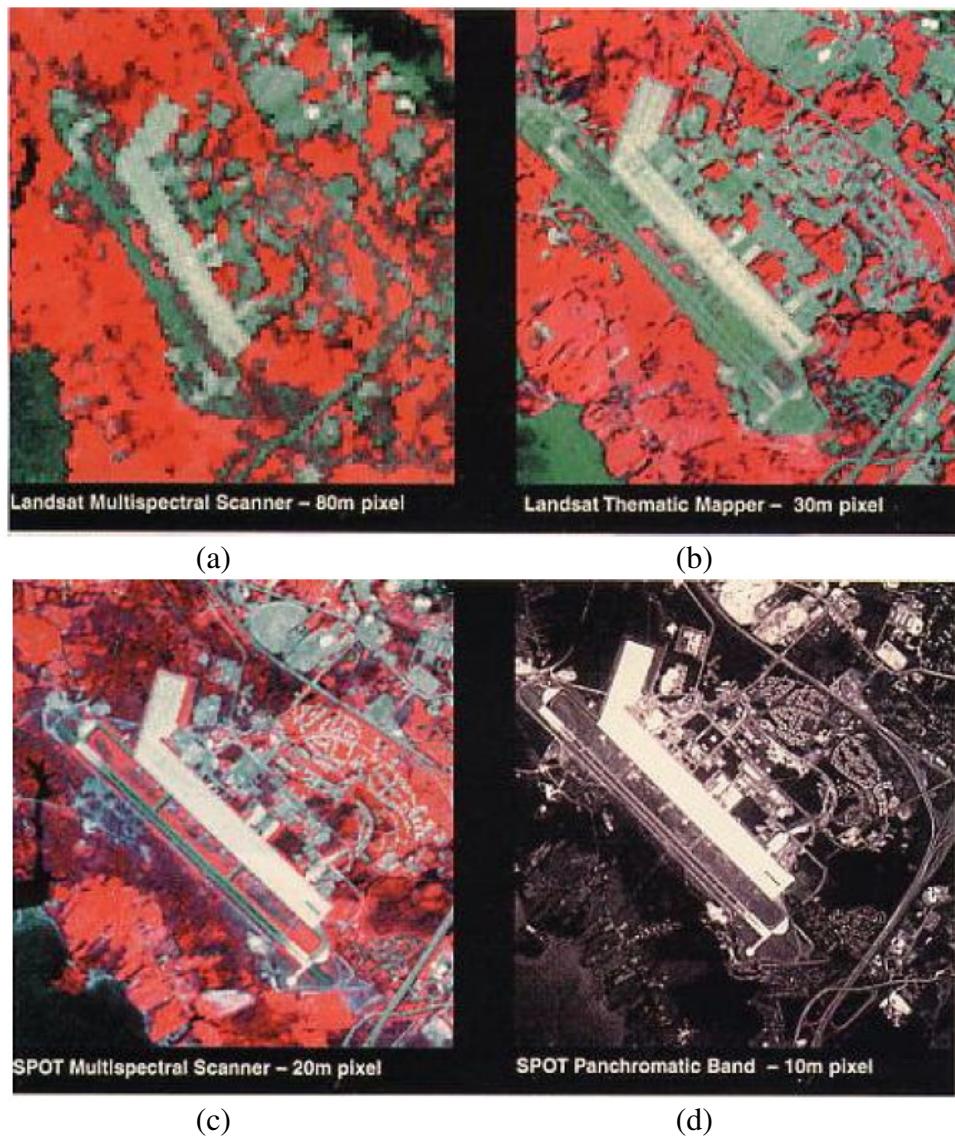
Piksela predstavlja najmanju površinu koju određeni senzor može detektovati i ta moć senzora se naziva prostorno razdvajanje ili rezolucija. Sateliti koji mjeru stanja i procese u atmosferi i okeanima imaju uglavnom velike piksele - tipično 1 km ili veće, jer se u tim područjima pojave na manjim udaljenostima ne mijenjaju značajnije. Niska (gruba) rezolucija predstavlja sliku koja je sastavljena od većih piksela, dok fina (visoka) rezolucija odgovara slici sastavljenoj od malih piksela. Proučavanje kopna na Zemlji, za razliku od atmosfere i okeana, zahtijeva mnogo veću prostornu rezoluciju (manje piksele) jer područja našeg interesovanja (ceste, građevine, rijeke, polja itd.) ne mogu biti jasno predstavljeni velikim pikselima.

Senzori koji se nalaze na satelitima LANDSAT uočavaju oblike veličine 30 m, dok senzori na francuskom satelitu SPOT (Systeme Probatoire d'Observation de la Terre) detektuju oblike veličine 10 - 20 m. Slika 1.2 prikazuje nekoliko satelitskih pogleda istog područja (Pease Developement Center Portsmauth u New Hampshire-u) u nekoliko različitih prostornih rezolucija kako bi se pokazao efekat veličine piksela na kvalitet slike. Slika 1.1 je dobijena pomoću senzora AVHRR (eng. Advanced Very High Resolution Radiometer) koji ima rezoluciju od 1100 m. Slika lijevo je veličine 15x15 piksela i predstavlja površinu od 16.5km x 16.5km. Da je prikazana manja površina na slici se ne bi vidjeli nikakvi detalji zbog malog broja piksela. Svijetli pikseli u sredini povećanog dijela slike predstavljaju aerodromsku pistu.



Slika 1.1 – Satelitska slika dobijena AVHRR senzorom rezolucije 1,1km

Slika 1.2a predstavlja isto područje „uhvaćeno“ pomoću multispektralnog skenera (Multispectral Scanner), sa 80 metarskim pikselom, koji se nalazi na LANDSAT satelitu. Na ovoj se slici, osim područja piste, može razabrati više detalja. Slika 1.2b je dobijena od LANDSATovog Thematic Mappera čiji je piksel 30 m i na njoj se već razabiru ceste i drugi detalji. Slika 1.2c je u 20 metarskoj rezoluciji Multispektralnog skenera na francuskom SPOT satelitu. Ovdje su vidljive i druge pojedinosti. Slika 1.2d je u 10 metarskoj rezoluciji načinjena pomoću Panchromatic imager-a na SPOT satelitu. Iz ovih primjera se vidi da se smanjenjem veličine piksela, povećava količina informacija za istu površinu, što je bilo i za očekivati. Dakle, o svrsi istraživanja (posmatranja) zavisiće koji senzori, odnosno koja rezolucija će biti upotrebljena.



Slika 1.2- Komparativno predstavljanje iste slike dobijene senzorima različitih rezolucija

LANDSAT, SPOT i neki NOAA sateliti su u polarnim orbitama koje su na visinama od 800 - 900 km. Kako satelit prolazi iznad područja posmatranja, podaci se prikupljaju po liniji posmatranja (eng. scan line) ispod satelita. Svaka linija pretraživanja

podijeljena je na elemente rezolucije (piksele) koji imaju konačnu površinu, određenu senzorovom prostornom rezolucijom. LANDSAT sateliti, na primjer pretražuju u zamahu od 185 km, s prostornom rezolucijom od 30 m.

Drugi važan aspekt satelitskog daljinskog snimanja je frekvencija prekrivanja (eng. Frequency of coverage) tj. učestalost kojom satelit prolazi iznad određene lokacije na Zemljinoj površini. Frekvencija prekrivanja zavisi od orbite na kojoj je satelit smješten, pri čemu je jasno da što je orbita na većoj visini potrebno je duže vrijeme da satelit obide Zemljinu kuglu.

Sateliti namjenjeni za praćenje atmosferskih pojava zahtijevaju učestalo prekrivanje jer je neophodno opažanje promjena koje se dešavaju u kratkom vremenu (sati i minute). Da bi se ovo postiglo sateliti se postavljaju u tzv. geostacionarne orbite. U takvoj orbiti satelitu koji putuje od zapada na istok na visini od 36500 km, potrebno je 24 sata da obide Zemlju, tako da izgleda da stoji u odnosu na istu lokaciju na Zemlji.

Iako se danas satelitski snimci mnogo više koriste u oblasti daljinskog snimanja, senzori postavljeni na avione omogućavaju veoma detaljno snimanje regiona na površini Zemlje i prikupljanje podataka sa bilo kojeg regiona u bilo koje vrijeme. Definicije o prostornoj rezoluciji senzora sa satelitskih platformi kao i principi mjerjenja ostaju iste za senzore na avionima. Na visinama na kojima se nalazi avion pri snimanju, senzori moraju da imaju veoma široke uglove snimanja (60-70 stepeni), za dovoljno široko snimanje područja. To uводи geometrijske distorzije jer se područje direktno ispod aviona snima manjom skalom nego područje koje je na ivici površine snimanja. Satelitski snimci zbog svoje veće udaljenosti od Zemljine površine u odnosu na avione (do 100 puta veća) mnogo su manje podložni geometrijskim distorzijama ovog tipa. Ipak senzori na avionima su mnogo fleksibilniji u mogućnostima da ponovo prikupe podatke o istim regionima iz drugih uglova i pravaca snimanja, za razliku od satelita kod kojih područje i vrijeme snimanja zavise isključivo od njihovih putanja. Upravo takva ponovljena snimanja istih područja omogućavaju redukciju geometrijskih nepravilnosti na snimcima dobijenih iz senzora na avionima. Geometrijski ispravljen vazdušni (aero) snimak, kod koga je skala uniformna na čitavom snimku, naziva se ortofoto ili ortofotografija. Ortofotografija se, na primjer, može koristiti za mjerjenje udaljenosti objekata na snimku s obzirom da predstavlja tačan prikaz Zemljine površine.

## 1.2 Spektralna analiza podataka

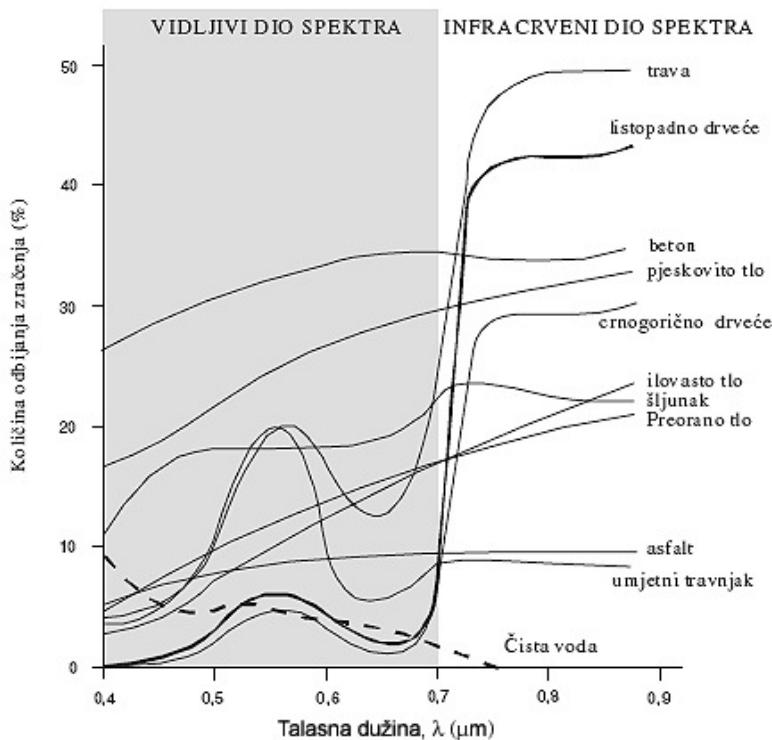
Elektromagnetsko zračenje koje prođe kroz atmosferu dolazi do površine Zemlje i objekata na njoj. To zračenje se naziva upadajuće zračenje i u kontaktu sa površinom objekata ono se mijenja po: intenzitetu, smjeru, talasnoj dužini, polarizaciji i fazi. Promjene koje nastaju karakteristične su za pojedine objekte jer ovise o njihovim fizičkim i hemijskim osobinama, a kod živih organizama i biljaka, i o njihovoj anatomskoj strukturi i fiziološkom stanju, respektivno. Svaki objekt može pristiglo zračenje reflektovati, propustiti ili apsorbovati. Svaki objekt može emitovati svoju energiju. Sve ove promjene se mogu proučavati uz pomoć daljinskog snimanja. Dobijeni podaci sa senzora tumače se i interpretiraju kako bi se prepoznali objekti i kako bi se otkrile njihove karakteristike ili uzroci promjena.

Jačina i količina zračenja koje uređaj za snimanje detektuje zavise od:

- osobine objekta da reflektuje elektromagnetno zračenje,
- osobine objekta da propušta elektromagnetno zračenje,
- osobine objekta da upija elektromagnetno zračenje,
- karakteristike površine objekta,
- mase objekta,
- položaja objekta,
- položaja Sunca u trenutku snimanja (azimut i visina),
- položaja uređaja za snimanje (azimut i visina),
- atmosferskih uticaja,
- karakteristika uređaja za snimanje i
- načina akvizicije i obrade prikupljenih podataka.

Uticaj svake navedene osobine na količinu i jačinu zračenja drugačiji je za različite talasne dužine, pa u zavisnosti od potrebe koriste se senzori koji mogu detektovati elektromagnetna zračenja u pojedinim željenim spektralnim opsezima. Npr., senzori na LANDSAT i SPOT satelitima detektuju sunčevu zračenje koje se reflektuje nazad u svemir od oblaka, okeana i kopna sa Zemljine površine. LANDSAT ima takođe i senzor za detekciju infracrvenog zračenja koje emituje Zemlja i njena atmosfera. Ovi senzori se nazivaju pasivni senzori jer samo primaju zračenje. Neki okeanografski sateliti aktivno šalju mikrotalasne (radarske) signale koje, kad se reflektuju od okeanskih valova, primaju nazad. To su aktivni senzori, i emituju i primaju zračenje. Svaki spektralni opseg nosi jedinstveni set informacija o Zemljinoj površini, jer svaki objekat ima jedinstvene i međusobno različite karakteristike refleksije i emisije (Slika 1.3). Na primjer, ozon apsorbuje ultraljubičasto zračenje pa se određivanje ozona u atmosferi vrši mjerenjem ultraljubičastog zračenja. Pomoću mikrotalasa posmatraju se ledene polarne kape, preko čijeg otapanja se može pratiti globalno zatopljenje. Vidljivi i infracrveni podaci upotrebljavaju se za procjenu stanja (zdravlja) usjeva, šuma i drugih oblika vegetacije Zemlje. Toplotno infracrveno zračenje upotrebljava se za određivanje temperature oblaka, tla i okeanskih površina.

Sada se testiraju hiperspektralni daljinski senzori koji razdvajaju dolazeće zračenje na stotine spektralnih opsega za primjenu u budućim satelitskim misijama. Spektralna rezolucija slike odnosi se na broj spektralnih opsega postignutih za svaki piksel. Kako se refleksija može mjeriti u uskim opsezima spektra (kanalima) kao funkcija talasne dužine, ona se naziva spektralno odbijanje i izražava se u procentima. Dijagram na kojem je prikazano spektralno odbijanje pojedinih prirodnih objekata kao funkcija talasne dužine naziva se kriva spektralnog odbijanja. Kako je kriva spektralnog odbijanja karakteristična za različite vrste objekata ona se koristi kao parametar za razlikovanje i prepoznavanje objekata na snimkama dobijenim pomoću uređaja za snimanje. Neki objekti mogu imati sličan tok krive u određenom opsegu spektra (Slika 1.3 - prirodna i umjetna travnata površina u vidljivom dijelu spektra 0,4 do 0,7  $\mu\text{m}$ ) da bi se u drugom dijelu spektra značajno razlikovali. Ta činjenica omogućava izbor onog dijela spektra u kojem će se objekti od interesa najbolje moći razlikovati.



Slika 1.3 – Spektralna karakteristika objekata za vidljivi i infracrveni dio spektra

Sateliti LANDSAT i SPOT detektuju podatke u vidljivom i infracrvenom području spektra. SPOTov multispektralni senzor snima u tri spektralna opsega: dva u vidljivom području (zeleni i crveni) i jedan u infracrvenom području. LANDSATov Thematic Mapper detektuje reflektovano sunčevu zračenje u šest opsega i topotopno infracrveno zračenje, koje emituje Zemlja, u sedmom opsegu. Od ovih šest opsega, tri su u vidljivom (plavo, zeleno i crveno), a ostali u infracrvenom pojasu i to u bližem infracrvenom pojasu NIR (eng. Near infrared) i srednjem infracrvenom pojasu MIR (eng. Middle infrared). Dio infracrvenog zračenja NIR je skoro potpuno apsorbovan u vodi, dok tlo i vegetacija imaju visoku refleksiju u NIR području. Dakle, NIR opsezi su korisni za razlikovanje tla i vode. Osim toga koriste se pri prostornom i sistematskom određivanju vegetacije te za utvrđivanje zdravlja određene biljne vrste. Srednji infracrveni pojasevi MIR su osjetljivi na sadržaj vlage pa se koriste u proučavanju vegetacije i lociranju oblaka, snijega i formacija leda. Pomoću toplinskih infracrvenih pojaseva mjeri se količina topoteke koju emituje neki objekt (temperatura nekog objekta se može mjeriti sa tačnošću većom od pola stepena celzijusa). Vidljivi opsezi pojedinačno ili zajedno s infracrvenima, govore i o drugim svojstvima kopna i voda. Hlorofil u biljkama apsorbuje plave i crvene pojaseve, dok zeleni pojas reflektuje. Stoga se ovi opsezi upotrebljavaju u određivanju biljnih vrsta i stanja zdravlja vegetacije. Određeni tipovi tla i formacija stijena povećavaju refleksiju crvenog dijela spektra. Voda povećava refleksiju plavog u odnosu na druge spektralne pojaseve. Vidljivi opsezi se obično upotrebljavaju za lociranje oblaka koji mogu biti satelitu nevidljivi u infracrvenim pojasevima (zbog iste temperature s temperaturom tla ili okeanske površine).

Upotrebom algoritama za analizu slika svi pikseli s istim spektralnim karakteristikama se svrstavaju u istu klasu, jer pikseli s jednakim spektralnim karakteristikama najčešće odgovaraju istom tipu zemljinog pokrivača, oblaka ili voda. Suprotno ne vrijedi jer svi pikseli određenog pokrivača tla, oblaka ili voda ne moraju pripadati istoj klasi, pa postoji daljnja potreba za grupisanjem klasa (na primjer prema raznim tipovima pokrivača tla). Slika koja je proizvedena razvrstavanjem piksela i bojanjem rezultirajućih klasa po nekom kodu, naziva se tematska mapa (eng. Thematic Map). U tematskoj mapi različite klase piksela su identifikovane i grupisane zajedno. Na primjer, svi pikseli koji su šuma mogu biti grupisani u jednu grupu i označeni "šuma", ili mogu biti grupisani u dvije grupe kao "crnogorica" i "bijelogorica", ili pak mogu biti grupisani kao "crni bor", "jela", "smreka" itd. Ograničenje ovakvom razlučivanju su sami senzori za daljinsko snimanje čije informacije mogu biti nejasne, odnosno neodređene. Na primjer asfaltno parkiralište i asfaltna krovna površina ili šljunčana plaža praktično su nerazlučive za senzor daljinskog snimanja. Ovo zahtjeva provjera na terenu (eng. "Ground Truthing"). Provjera i mjerena na terenu omogućavaju povezivanje daljinskih ispitanih podataka sa stvarnim podacima našeg prirodnog okoliša, pa da bi se potvrdili zaključci zasnovani na daljinskom istraživanju potrebno je obići teren. Ova tehnika je samo jedna od tehnika interpretiranja multispektralnih satelitskih i aero podataka. Druge tehnike uključuju matematičke formule pomoću kojih se podaci dva ili više spektralnih opsega koriste za izvođenje novog pojasa. Na primjer, dva termalna infracrvena pojasa se upotrebljavaju da bi se izvela temperatura morske površine.

Sa porastom veličine baza sa geografskim slikama javila se potreba da se razviju metodi za efikasnu reprezentaciju informacija sa slike, za brza pretraživanja i manipulaciju slikama u bazi. Pod efikasnom reprezentacijom se podrazumijeva način predstavljanja i opisa slike u formi pogodnoj za daljnju obradu. U tu svrhu se za kvantitativni opis slike koriste numeričke predstave obilježja slike (deskriptori) kao što su tekstura, oblik (kontura), boja itd. Sistemi za pretraživanje baza slika u svojim algoritmima mogu da koriste više ovih atributa za opis slika i samim tim ostvarenje bržeg i efikasnijeg pretraživanja. Tim načinom se i došlo do ideje da se na osnovu teksture mogu izdvajati slike koje sadrže željena geografska obilježja, što predstavlja uvod u jedan od korisnih algoritama za obradu slika dobijenih daljinskim snimanjem. Deskriptor teksture se dobija multirezolucionom analizom pomoću banke Gaborovih filtera pri čemu je Gaborov filter propusnik opsega, a banka se projektuje tako da pokrije čitav frekventni opseg. Korištenjem teksture kao vizuelnog obilježja slike omogućeno je pretraživanje baza slika gdje bi rezultat pretraživanja bile slike sa sličnim geografskim sadržajem kao što su: tip vegetacije, parkinzi, oblast kuća, industrijska zona, itd.

Prve tri glave daju uopštenu teoretsku podlogu neophodnu za shvatanje konkretnе implementacije sistema za prepoznavanje obilježja na aero i satelitskim slikama.

Glava 2 – U ovoj glavi je dat uvod u pojam klasifikacije i šta on podrazumijeva, te kako izgleda blok šema sistema za prepoznavanje. Svaki od blokova su opisani uopšteno, uz kratak osvrt na predloženo rješenje u paragrafu 2.5

Glava 3 – Daje teoretsku podlogu i objašnjenje vizuelnih obilježja slike. Zatim se detaljnije bavi obilježjem teksture i načinom dobijanja numeričke reprezentacije tog obilježja.

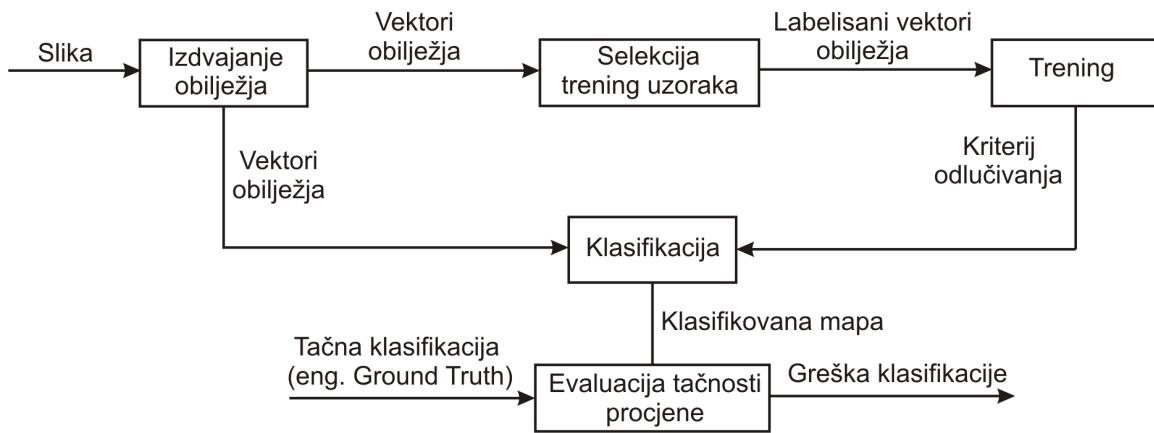
Glava 4 – Daje pregled osnovne podjele neuronskih mreža i njihovu primjenu, kako bi se stekao bolji uvid kojem tipu neronskih mreža pripadaju samo-organizujuća mapa i LVQ mreža koje su korištene u radu. Obrazlaganje je praćeno Matlab kodom.

Glava 5 – Daje detaljnu specifikaciju realizovanog sistema, rezultate klasifikacije i obrazloženje dobijenih rezultata.

Glava 6 – Daje zaključak rada i kratak pregled i ideju za budući rad.

## 2. SISTEM ZA PREPOZNAVANJE OBILJEŽJA NA VAZDUŠNIM I SATELITSKIM SLIKAMA

Klasifikacija je proces dodjeljivanja labele tj. predefinirane kategorije (ili klase) svakom pikselu slike na osnovu njegovih osobina (vrijednost svjetline, nivo sivila, multispektralne vrijednosti itd.)[2]. Na primjer, labele 1, 2, 3 i 4 mogu biti dodijeljene pikselima koji određuju šumu, poljoprivrednu kulturu, urbano naselje i vodu, respektivno. Za očekivati je da klasifikacija podrazumijeva i proces odlučivanja na osnovu zadatih parametara. Generalno gledano, algoritmi klasifikacije se mogu podijeliti na slijedeće faze: izdvajanje obilježja, treniranje (učenje), labelisanje i opcionalno, validaciju (procjenu tačnosti) – Slika 2.1.



Slika 2.1 – Proces klasifikacije

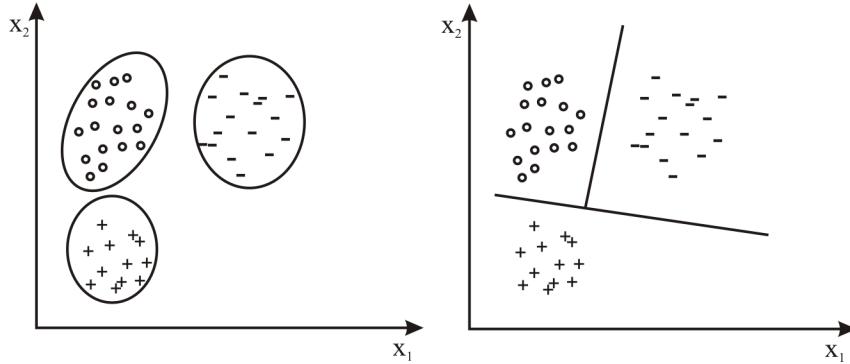
### 2.1 Izdvajanje obilježja

Obilježja su numeričke karakteristike slike na osnovu kojih se donose odluke o klasifikaciji. Dakle, ona omogućavaju svrstavanje slika u klase. Vrijednosti obilježja bi za piksele ili regije slika koji pripadaju istoj klasi trebale biti što bliže, a za piksele i regije različitih klasa što dalje. Svakom pikselu ili regionu se dodjeljuje vektor obilježja kreiran na osnovu najčešće više obilježja, koji označava labelu klase kojoj je piksel ili region dodjen. Vektor obilježja može npr. biti jednodimenzionalni niz multispektralnih mjerena na jednom pikselu, ili kombinacija teksture i spektralnih vrijednosti ili samo reprezentacija teksture.

### 2.2 Treniranje (učenje)

Treniranje ili učenje je proces u kojem se vrši estimacija statističkih parametara skupa uzoraka na osnovu kojih se realizuje kriterijum odlučivanja. Često se koriste klasifikatori koji su u potpunosti određeni ako su poznate neke statističke osobine uzoraka [3]. Upravo dodjela labela svakom vektoru obilježja se vrši na osnovu kriterijuma odlučivanja. U prostoru obilježja granice između klasa mogu biti krive ako se

radi o dvodimenzionalnom prostoru ili hiperpovršine u slučaju višedimenzionalnog prostora obilježja. Primjer dva načina definisanja granica između klasa je predstavljen na slijedećoj slici. Pretpostavljeno je da je vektor obilježja oblika  $\mathbf{x} = [x_1, x_2]^T$ , što znači da je prostor obilježja dvodimenzionalan. Vektori su klasifikovani u tri klase pri čemu su vektori dodijeljeni prvoj klasi označeni sa "o", vektori dodijeljeni drugoj klasi označeni sa "+" i vektori dodijeljeni trećoj klasi sa "-". U prvom slučaju vektori pridruženi različitim klasama odvojeni su elipsama (Slika 2.2a), a u drugom slučaju pravama (Slika 2.2b).



Slika 2.2 - Primjeri podjele/klasifikacije prostora obilježja

U višedimenzionalnom prostoru te granice postaju hiperelipsoide i hiperravnini. U zavisnosti od izbora numeričke reprezentacije osobina piksela ili regiona, tj. načina dobijanja vektora obilježja klase, mogu biti lako ili teško separabilne. Zato je pri klasifikaciji veoma važan izbor odgovarajućih deskriptora na osnovu kojih se vrši separacija klasa.

Neka je  $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$  n-dimenzionalni vektor uzorka. Za  $M$  klase  $\omega_1, \omega_2, \dots, \omega_M$  osnovni problem prepoznavanja se svodi na pronalaženje  $M$  funkcija odlučivanja  $d_1(\mathbf{x}), d_2(\mathbf{x}), \dots, d_M(\mathbf{x})$  sa osobinom da, ako uzorak  $\mathbf{x}$  pripada klasi  $\omega_i$ , bude zadovoljena slijedeća nejednakost:

$$d_i(\mathbf{x}) > d_j(\mathbf{x}), j = 1, 2, \dots, M; j \neq i. \quad (2.1)$$

Granica odlučivanja koja razdvaja klasu  $\omega_i$  od  $\omega_j$  je određena vrijednostima  $\mathbf{x}$  za koje je:

$$d_i(\mathbf{x}) - d_j(\mathbf{x}) = 0. \quad (2.2)$$

Uobičajena praksa je da funkcija:

$$d_{ij}(\mathbf{x}) = d_i(\mathbf{x}) - d_j(\mathbf{x}) = 0 \quad (2.3)$$

određuje granicu klase. Ako je  $d_{ij}(\mathbf{x}) > 0$  uzorak pripada klasi  $\omega_i$ , a ako je  $d_{ij}(\mathbf{x}) < 0$  zorak pripada klasi  $\omega_j$ .

Neki od primjera kriterijma odlučivanja su:

- *Minimalna udaljenost* – svaka klasa je opisana srednjom vrijednošću (prototipom) vektora obilježja uzorka iz tih klasa. Klasifikacija na osnovu minimalne udaljenosti je pridruživanje uzorka (vektora) onoj klasi čiji mu je prototip najbliži.

- *Korelacija* – kriterijum odlučivanja se zasniva na činjenici da je vrijednost korelacije maksimalna kada se na slici pronađe dio koji je najsličniji traženoj podslici.
- *Minimalna vjerovatnoća greške klasifikacije* – funkcija odlučivanja na osnovu minimalne vjerovatnoće zahtjeva poznavanje funkcije gustine raspodjele uzoraka u svakoj klasi kao i vjerovatnoću pojavljivanja svake od klase. Najčešće se za funkciju gustine uzoraka u klasi prepostavlja Gausova raspodjela i što je ova pretpostavka bliža realnosti, to će se klasifikator bolje približavati minimumu prosječnog rizika u klasifikaciji. Ovaj klasifikator se naziva Bayesov klasifikator.

U ovom radu neće biti matematički razmatrani navedeni kriterijumi odlučivanja, za više detalja obratite se referenci [3]. Ipak, u praksi su često statističke osobine klase nepoznate i nemoguće ih je procijeniti. Zato se koriste metodi gdje se funkcija odlučivanja formira kroz proces učenja neuronske mreže. Neuronske mreže Više o neuronskim mrežama u Glavi 4.

## 2.3 Labelisanje

Na osnovu kriterijuma odlučivanja svakom pikselu ili regionu je dodijeljena labela. Ipak, labele kod multispektralnih slika ili labele dodijeljene samo na osnovu vektora obilježja često nisu klase od interesa koje bi dale željenu informaciju o osobinama piksela ili regiona. Može se desiti da jedan dio labela predstavlja šumu, drugi dio poljoprivrednu kulturu te je grupisanje labela i relabeliranje neophodno kako bi se dobile labele od fizičkog značaja. Nekad je potrebno izvršiti i fino podešavanje granica labela u cilju poboljšanja tačnosti klasifikacije.

## 2.4 Procjena tačnosti (validacija)

Poželjno je da rezultati klasifikacije budu validirani poredeći sa istinskom klasifikacijom slikanog područja što može biti postignuto na osnovu mapa ili izviđanjem terena.. Ovaj način je zahtjevniji u odnosu na procjenu tačnosti klasifikacije pomoću test skupa. Najbolje utvrđivanje se postiže terenskom provjerom tla simultano sa akvizicijom podataka sa daljinskog snimanja.

## 2.5 O predloženom rješenju

Realizovani sistem klasifikacije se bavi semantičkom segmentacijom dijelova vazdušnih i satelitskih slika na osnovu izračunavanja deskriptora teksture. Deskriptori teksture su dobijeni filtriranjem slike Gaborovom bankom filtera, dok je neuronska mreža korištena da prepozna koje obilježje sadrži ulazna slika i da joj dodjeli odgovarajuću klasu. Pristup problemu prepoznavanja obilježja korišten u ovom radu može da se iskoristi i proširi po potrebi. Iako je testiranje vršeno na vazdušnim snimcima, isti postupak analize može se primjeniti na satelitke slike (SPOT i LANDSAT).

### **3. DESKRIPTOR TEKSTURE**

U ovoj glavi će biti opisan način kako predstaviti i opisati svaki od regiona slike u formi pogodnoj za daljnju obradu.

#### **3.1 Vizuelna obilježja slike**

Vizuelna obilježja su karakteristične primitivne osobine ili atributi slike. [4] Postoje prirodna i vještačka vizuelna obilježja, gdje su prirodna određena vizuelnom percepцијом slike, dok su vještačka obilježja rezultat obrade slike. Prirodna obilježja mogu biti luminancija (objektivna vrijednost svjetline) regiona piksela ili nivo sivila regiona teksture. Primjeri vještačkih obilježja su histogrami slike i frekventni spektri.

Na osnovu vizuelnih obilježja moguće je izvršiti izdvajanje regionala slike sa određenim osobinama (segmentacija slike), identifikacija tih regionala ili labelisanje istih (klasifikacija slike). Neka od tih obilježja su: boja, tekstura, oblici objekata, raspored ivica, itd. [5] U procesu izdvajanja, obilježja su predstavljena numeričkim deskriptorima. Tako na primjer, kolor-histogram je deskriptor boje, energije izlaza iz Gaborove banke filtara su deskriptor teksture, itd. Bitno je napomenuti da za isto obilježje može postojati više različitih deskriptora.

Poželjno je da deskriptori koji se koriste za reprezentaciju slike zadovoljavaju slijedeće zahtjeve:

1. Opisuju sadržaj slike,
2. Omogućavaju definiranje neke metrike tj. mjere sličnosti slike,
3. Omogućavaju uvođenje šeme za indeksiranje kako bi pristup podacima bio efikasniji.

Prvi zahtjev je očigledan s obzirom na to da je zadatak deskriptora reprezentacija slike sa smanjenom količinom informacija, tj. smanjenom redundansom. Izdvajanje obilježja i izračunavanje deskriptora preslikava slike u tačke u prostoru obilježja. U procesu klasifikacije slika potrebno je definisati neku metriku, tj. mjeru sličnosti slika u prostoru obilježja. Pri odabiru metrike bilo bi dobro obratiti pažnju da ta metrika bude perceptualno zasnovana, tj. da sličnim slikama odgovara bliska fizička pozicija tačaka u prostoru obilježja.

Tekstura slike kao obilježje je uzeto kao osnova izdvajanja geografskih karakteristika dijelova vazdušnih i satelitskih slika. Pod izdvajanjem geografskih obilježja se podrazumijeva prepoznavanje odabranih klasa slike kao što su zelenila, industrijske zone, kuća itd. Obilježje teksture je dakle korišteno za pronalaženje i izdvajanje slika sa sličnim geografskim obilježjem. Prema tome, naredni dio glave je posvećen obilježju teksture, odabranom deskriptoru i osnovama klasifikacije slika na osnovu deskriptora teksture.

## 3.2 Obilježje teksture

Proces klasifikacije regiona slike baziran je na teksturi sadržaja tog regiona. Iako ne postoji formalna definicija teksture, intuitivno za opisivanje teksture se koriste odrednice kao što su glatkoća, grubost i npr. pravilnosti kao što su usmjerenost, periodičnost itd. [6]



(a) glatkoća

(b) grubost

(c) usmjerenost

Slika 3.1– Primjeri tekstura sa perceptualnim osobinama glatkoće, grubosti i usmjerenosti

U procesu opisivanja teksture regiona mogu se razdvojiti tri pristupa: statistički, strukturni i spektralni [6]. Statistički pristup vodi ka karakterizaciji tekstura kao glatke, grube, zrnaste itd. Strukturne tehnike opisa se baziraju na rasporedu atributa, tako da one omogućavaju opis teksture u kojoj, na primjer, dominiraju pravilne paralelne linije. Spektralne tehnike se baziraju na osobinama transformacija i omogućavaju, na primjer pronalaženje globalne periodičnosti detekcijom vrhova u Furijeovom spektru teksture. Gaborovi deskriptori spadaju u grupu spektralnih deskriptora.

Fokus pri pronalaženju obilježja na aero slikama u ovom radu je stavljen na dobijanje informacija iz teksture slike. Poredeći sa drugim multirezolucionim deskriptorima teksture pokazalo se da Gaborov deskriptor obezbjeđuje najveću tačnost u pronalaženju obilježja [7].

## 3.3 Gaborov deskriptor teksture

Gaborovi banka filtri se mogu posmatrati kao detektori ivica koji imaju podesivu orijentaciju i skalu, pa se informacija o teksturi upravo može dobiti izračunavanjem statistike izlaza tih filtera. Izlazi iz banke Gaborovih filtera odgovaraju koeficijentima wavelet dekompozicije korištenjem Gaborove baze.

### 3.3.1 *Gaborov filter i banka filtera*

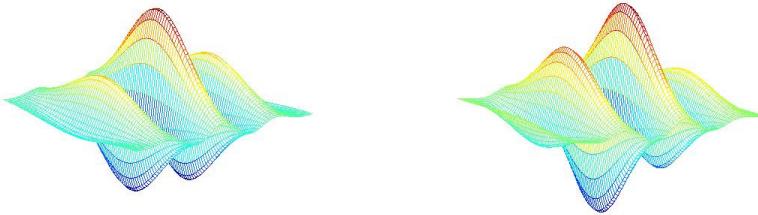
Gaborov filter je linearni filter propusnik opseg čiji je impulsni odziv definisan kao Gausova funkcija modulisana kompleksnom sinusoidom što je matematički predstavljeno slijedećom jednačinom:

$$g(x, y) = \left( \frac{1}{2\pi\sigma_x\sigma_y} \right) \exp \left[ -\frac{1}{2} \left( \frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2} \right) \right] \cdot \exp[2\pi jWx], \quad (3.1)$$

gdje je  $W$  frekvencija Gaborove funkcije,  $\sigma_x$  i  $\sigma_y$  određuju njen frekvencijski opseg [8].

Gabor je pokazao da upravo takve elementarne funkcije minimizuju združene prostorne i frekventne neodređenosti [9].

Realni i imaginarni dio Gaborove funkcije (3.1) su prikazani na slikama 3.2a i 3.2b.



Slika 3.2 - Realni dio (a) i imaginarni dio impulsnog odziva Gaborovog filtra

Uzima se da je  $g(x, y)$  majka-wavelet (osnovna funkcija), pa se klase funkcija dobijene dilatacijom (skaliranjem) i rotacijom  $g(x, y)$  nazivaju Gaborovi waveleti. Dakle, banka Gaborovih filtera se generiše dilatacijom i rotacijom funkcije (3.1), pa se dobija:

$$g_{mn}(x, y) = a^{-m} g(x', y'), \quad (3.2)$$

pri čemu su  $a > 0$ , a  $m$  i  $n$  indeksi skale i orijentacije waveleta respektivno, dalje slijedi:

$$x' = a^{-m} (x \cos \theta + y \sin \theta), \quad (3.3)$$

$$y' = a^{-m} (-x \sin \theta + y \cos \theta), \quad (3.4)$$

gdje je  $\theta = n\pi / K$ , a  $K$  je ukupan broj orijentacija. Skalirajući faktor  $a^{-m}$  normalizira izlaze filtra (energije). Furijeova transformacija funkcije  $g(x, y)$  je

$$G(u, v) = \exp \left\{ -\frac{1}{2} \left[ \frac{(u-W)^2}{\sigma_u^2} + \frac{v^2}{\sigma_v^2} \right] \right\} \quad (3.5)$$

gdje su  $\sigma_u = 1/2\pi\sigma_x$  i  $\sigma_v = 1/2\pi\sigma_y$ .

Gaborove funkcije čine neortogonalnu bazu. Neortogonalnost Gaborovih waveleta implicira da postoji redundantna informacija u koeficijentima transformacije, pa su slijedeći koraci preduzeti u cilju smanjivanja redundantne. Neka su  $U_l$  i  $U_h$  donja i gornja centralna frekvencija od interesa. Neka je  $N$  broj orijentacija, a  $M$  broj skala u multirezolucionoj dekompoziciji. Da bi se redundansa smanjila potrebno je osigurati da se polovine magnituda odziva filtra u frekventnom domenu dodiruju, pa se za računanje parametara filtra  $\sigma_u$  i  $\sigma_v$  (odnosno  $\sigma_x$  i  $\sigma_y$ ) koriste slijedeće formule:

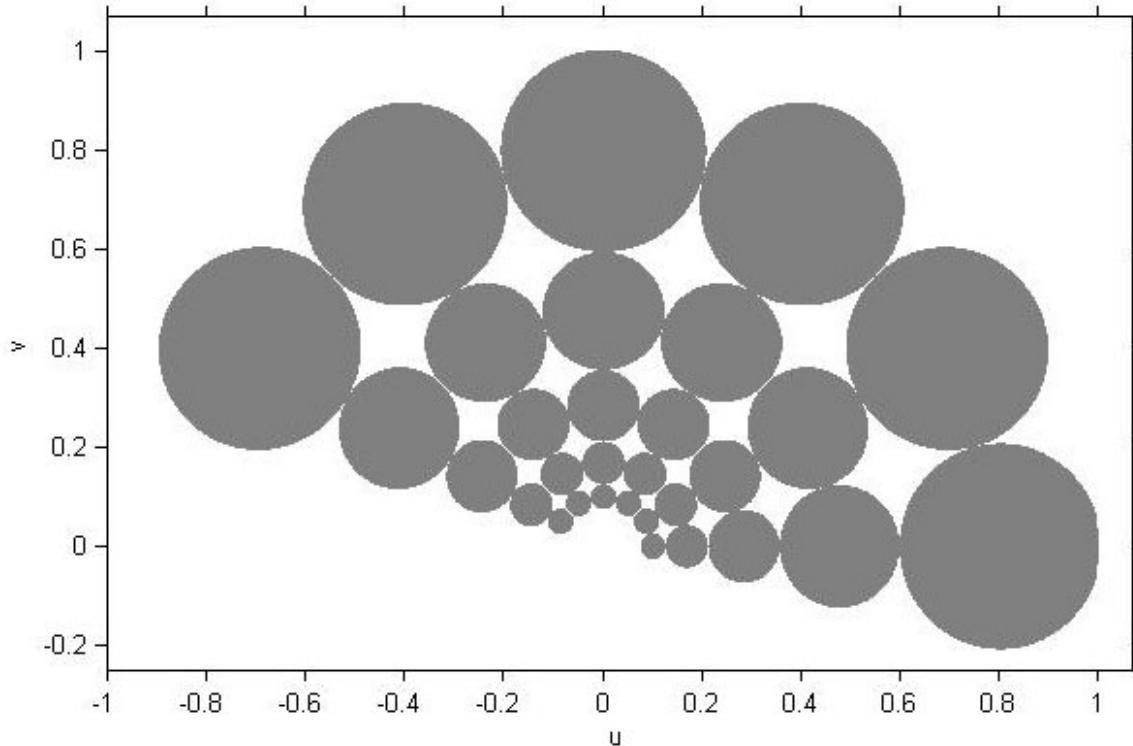
$$a = (U_h / U_l)^{\frac{1}{M-1}}, \quad (3.6)$$

$$\sigma_u = \frac{(a-1)U_h}{(a+1)\sqrt{2\ln 2}}, \quad (3.7)$$

$$\sigma_v = \tan\left(\frac{\pi}{2N}\right) \left[ U_h - 2\ln\left(\frac{2\sigma_u^2}{U_h}\right) \right] \left[ 2\ln 2 - \frac{(2\ln 2)^2 \sigma_u^2}{U_h^2} \right]^{\frac{1}{2}}, \quad (3.8)$$

gdje je  $W = U_h$ , a  $m = 0, 1, \dots, M-1$ .

Da apsolutne vrijednosti intenziteta na slici ne bi uticale na izlaze filtra, realni dio Gaborove funkcije treba da ima nultu srednju vrijednost što se postiže dodavanjem odgovarajuće konstante ili izjednačavanjem  $G(0,0)$  u jednačini (3.5) sa nulom. Primjer Gaborove banke filtera sa  $M=5$  skale i  $N=6$  orientacija, uz  $U_l=0.05$  i  $U_h=0.4$  je dat na slijedećoj slici, Slika 3.3.



Slika 3.3 – Konture krugova predstavljaju polovinu maksimalne magnitудне karakteristike izlaza Gaborove banke filtera. Parametri su  $U_h = 0.4$ ,  $U_l = 0.05$ ,  $M = 5$ ,

$$N = 6.$$

### 3.3.2 Reprezentacija oblježja teksture

Za sliku  $I(x, y)$  izlaz iz Gaborove banke filtara  $g_{mn}(x, y)$  je ustvari Gaborova wavelet transformacija slike data sa:

$$W_{mn}(x, y) = \sum_{x'} \sum_{y'} I(x', y') g_{mn}^*(x - x', y - y'). \quad (3.9)$$

Prepostavljajući da regioni slike  $I(x, y)$  imaju homogenu teksturu, za reprezentaciju tih regiona se koristi srednja vrijednost  $\mu_{mn}$  i standardna devijacija  $\sigma_{mn}$  transformacionih koeficijenata tj. :

$$\mu_{mn} = \sum_x \sum_y |W_{mn}(x, y)|, \quad (3.10)$$

$$\sigma_{mn} = \sqrt{\sum_x \sum_y (|W_{mn}(x, y)| - \mu_{mn})^2}. \quad (3.11)$$

Deskriptor tekture se formira izračunavanjem  $\mu_{mn}$  i  $\sigma_{mn}$  za svaki Gaborov filter iz banke:

$$TD = [\mu_{00} \ \sigma_{00} \ \mu_{01} \ \sigma_{01} \cdots \mu_{M-1,N-1} \ \sigma_{M-1,N-1}]^T \quad (3.12)$$

Za praktične potrebe rada po preporuci iz [10] realizovana je Gaborova banka filtara sa pet skala i šest orientacija. U tom slučaju je deskriptor tekture 60-dimenzionalni vektor.

Ako se uzme da su sa  $i$  i  $j$  označeni regioni slike onda su odgovarajući deskriptori tekture označeni sa  $TD_i$  i  $TD_j$  respektivno. Udaljenost dva deskriptora se određuje korištenjem težinske metrike Minkovskog sa  $p=1$ :

$$d(TD_i, TD_j) = \sum_m \sum_n \left| \frac{\mu_{mn}^{(i)} - \mu_{mn}^{(j)}}{\alpha(\mu_{mn})} \right| + \left| \frac{\sigma_{mn}^{(i)} - \sigma_{mn}^{(j)}}{\alpha(\sigma_{mn})} \right|, \quad (3.13)$$

pri čemu su  $\alpha(\mu_{mn})$  i  $\alpha(\sigma_{mn})$  standardne devijacije  $\mu_{mn}$  i  $\sigma_{mn}$  na cijeloj bazi i koriste se za normalizaciju pojedinih komponenti deskriptora.

### 3.3.3 Invarijantnost na rotaciju

Pri pretraživanju i klasifikaciji aero i satelitskih slika veoma je bitno da deskriptor tekture bude invarijantan na rotaciju [11]. Kako deskriptor tekture definisan jednačinom (3.12) nije invarijantan na rotaciju, potrebno ga je modifikovati. Neka su, npr. energije tekture  $I(x, y)$  sa dominantnom orijentacijom  $i\pi/N$  na skali  $m$  dobijene prema jednačini (3.10):

$$[\mu_{m,0} \ \mu_{m,1} \dots \mu_{m,i} \dots \mu_{m,N-1}] \quad (3.14)$$

pri čemu  $\mu_{m,k}$  odgovara energiji izlaza Gaborovog filtra na skali  $m$  sa orijentacijom

$k\pi/N$ . Neka su energije tekture  $I'(x, y)$ , koja je rotirana verzija  $I(x, y)$  sa dominantnom orijentacijom 0, takođe na skali  $m$  date sa:

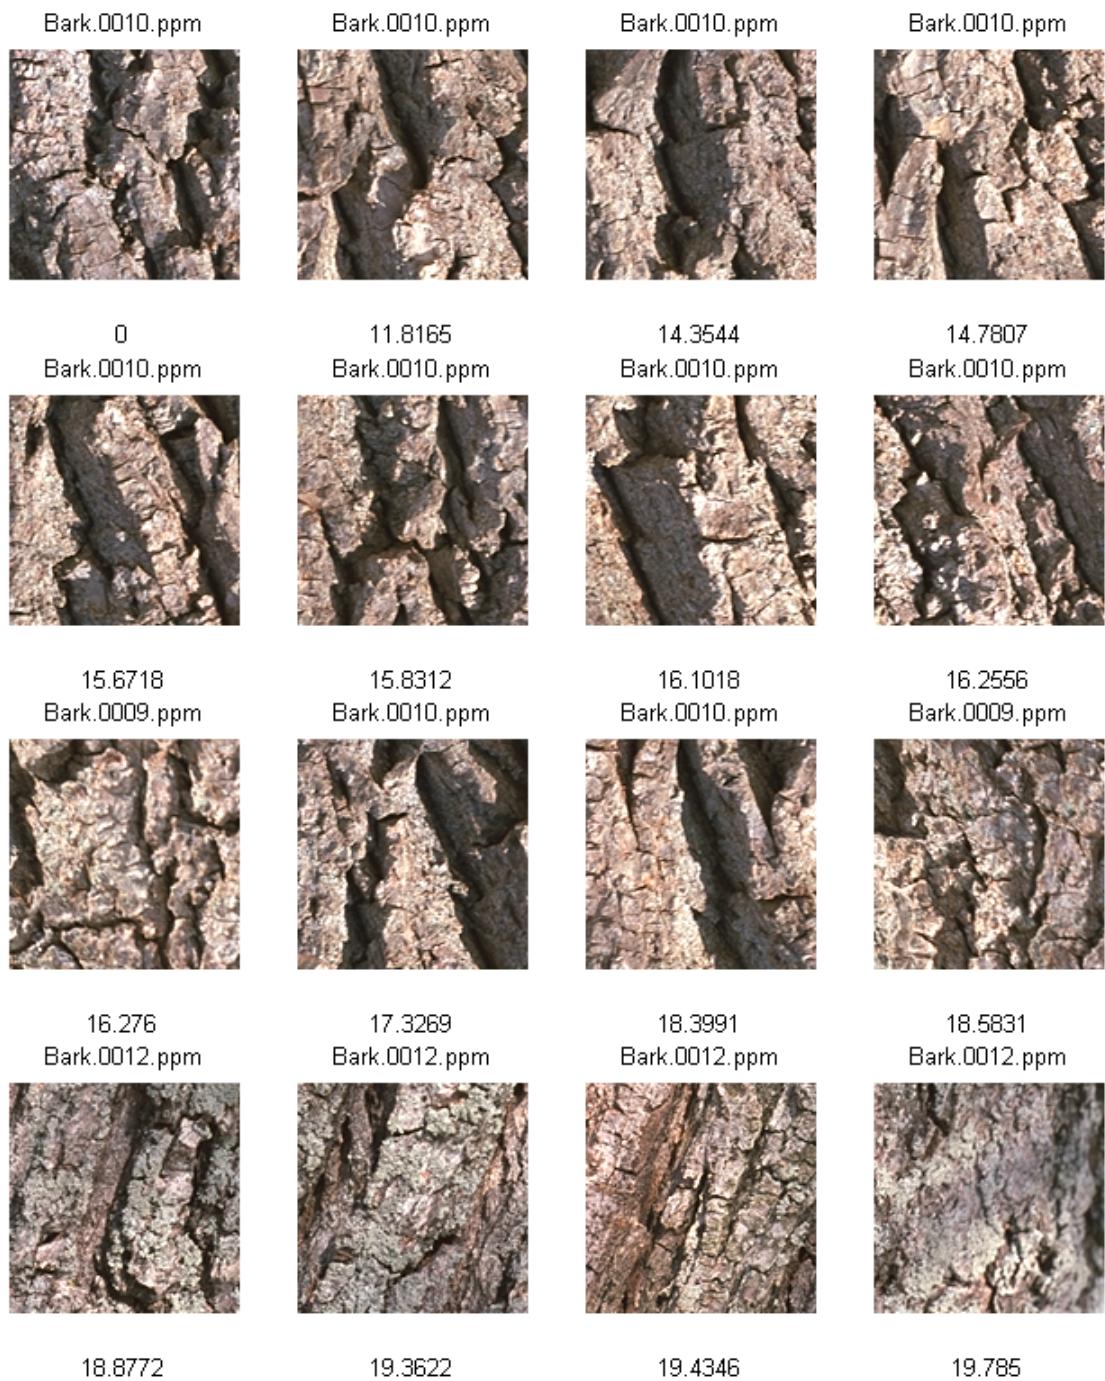
$$\begin{bmatrix} \mu'_{m,-i} & \mu'_{m,1-i} \dots \mu'_{m,0} \dots \mu'_{m,N-1-i} \end{bmatrix}, \quad (3.15)$$

gdje važi  $\mu_{m,k} = \mu'_{m,k-i}$ . Kako se rotacijom za  $180^\circ$  raspodjela energija ne mijenja, energije teksture  $I'(x, y)$  se mogu prikazati vektorom:

$$\begin{bmatrix} \mu'_{m,-i+N} & \mu'_{m,1-i+N} \dots \mu'_{m,0} \dots \mu'_{m,N-1-i} \end{bmatrix}. \quad (3.16)$$

Ovaj vektor predstavlja cirkularni pomak vektora (3.14) za  $i$  poziciju. Prema tome, invarijantnost na rotaciju je moguće postići cirkularnim pomakom deskriptora (3.12) tako da oni odgovaraju dominantnoj orijentaciji teksture.

Na slici 3.4 je dat rezultat pretraživanja u Visual Texture bazi tekstura sa 167 slika veličine 512x512 piksela. O ovoj bazi će biti više riječi u glavi 5. Upit je prvi blok veličine 128x128 piksela sa izdijeljene slike Bark.0010.ppm. Prikazuje se prvih 15 najsličnijih blokova u odnosu na blok upit koji se nalazi u lijevom gornjem uglu. Pošto su slike veličine 512x512 piksela dijeljene na 16 blokova, iscrtavano je 16 blokova jer je realno očekivati da su najsličniji blokovi bloku upita upravo oni dobijeni dijeljenjem sa slike 512x512 veličine. Deskriptori tekstura blokova su upoređivani prema udaljenosti dobijenih na osnovu (3.13). Blokovi su iscrtavani od najbližeg prema najdaljem i to odozgo prema dole i slijeva na desno. Ovim primjerom je pokazana uspješnost deskriptora teksture u reprezentaciji sadržaja blokova.



Slika 3.4 - Primjer pretraživanja Visual Texture baze slika na osnovu sličnosti teksura. Upit je slika u gornjem lijevom uglu. Sličnost rezultata sa upitom opada idući sa lijeva na desno i odozgo prema dole. Iznad slika je naznačeno ime fajla koji su prethodno ručno anotirani. Ispod slika su udaljenosti od upita na osnovu jednačine (3.13) . Slike su veličine 128x128, a prikazano je samo najsličnijih 16 tekstura iz baze.

## 4. NEURONSKE MREŽE

U ovoj glavi je dat pregled podjele neuronskih mreža i uopšteno objašnjenje istih. Veća pažnja je posvećena algoritmima samo-organizujuća mapa (SOM – eng. Self-Organizing Map) i linearna vektorska kvantizacija (LVQ – eng. Linear Vector Quantization) koji su korišteni kao klasifikatori za potrebe implementacije.

Neuronske mreže se prvi put spominju pedesetih godina ovog stoljeća, tačnije na konferenciji Dartmouth Summer Research Project on Artificial Intelligence koja je najavila ostvarivanje vizije kompjuterskog modela koji će u nekim temeljnim principima oponašati funkcionisanje mozga [12]. Neuronska informatika se pojavljuje kao alternativa Von Neumann-ovim računarima i nastoji simulirati ili ostvariti paralelnu obradu informacija koju koristi ljudski mozak dok razmišlja, sjeća se i rješava probleme. Za razvoj neuronskih mreža od presudnog je značaja nekoliko događaja:

- 1943 - McCulloch i Pitts postavljaju temelje za razvoj neuronskih mreža tako što prvi dokazuju da neuroni mogu imati dva stanja (aktivan i neaktivno) i da njihova aktivnost zavisi od nekog praga vrijednosti.
- 1949 - Hebb prvi predložio pravilo kojim se opisuje proces učenja (Hebb-ovo pravilo)
- 1956 - Dartmouth Summer Conference na kojoj su Rochester i skupina autora predstavili prvu simulaciju Hebb-ovog modela koja je preteča modela neuronskih mreža
- 1958 - Rosenblatt razvio prvu neuronsku mrežu perceptron, koja je dvoslojna i nije mogla rješavati probleme klasifikacije koji nisu linearne separabilni (npr. XOR problem)
- 1974 - razvijena višeslojna perceptron mreža - MLP (Paul Werbos), kao preteča mreže "prostiranje unazad" (eng. Backpropagation mreže), koja prevladava nedostatak perceptronu uvođenjem učenja u skrivenom sloju
- 1986 - Backpropagation mrežu usavršuju Rumelhart, Hinton i Williams, ona vraća ugled neuronskim mrežama, jer omogućava aproksimaciju gotovo svih funkcija i rješavanje praktičnih problema

Od tada raste naučni i komercijalni interes za neuronske mreže. Razvijeni su brojni algoritmi za neuronske mreže, a najveću komercijalnu upotrebu do danas ima mreža "prostiranje unazad".

### 4.1 Definicija i pojам neuronske mreže

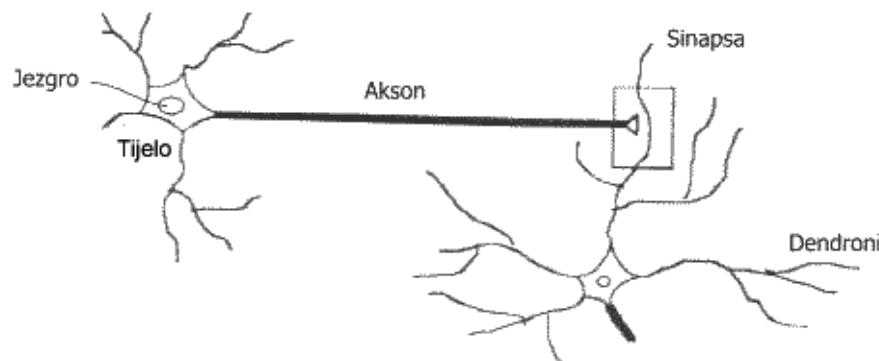
Jedna od definicija neuronske mreže glasi:

Neuronska mreža je međusobno povezan skup procesnih elemenata za obradu, jedinica ili čvorova, čiji se načini djelovanja temelje na neuronima mozga biološkog bića. Sposobnost obrade mreže zavisi od jačine veza među tim jedinicama, a postiže se kroz proces adaptacije ili učenjem iz skupa primjera za uvježbavanje [13]. Dakle, neuronska mreža je jedan oblik implementacije sistema vještacke inteligencije. Procesne elemenate

nazivamo još vještačkim neuronima. Cilj neuronskih mreža je simulirati sposobnost koju imaju ljudi da dobro prepoznaju oblike, lica i glasove, a iskoristiti mogućnosti računara da izvršavaju numeričke proračune i rade s velikom količinom podataka.

Bitno je napomenuti da se pod pojmom neuronska mreža podrazumijeva vještačka neuronska mreža. Neuronske mreže je najlakše objasniti i shvatiti pomoću analogije sa biološkim neuronskim mrežama.

Svaki neuron je specijalizovana ćelija u biološkoj neuronskoj mreži, kao što je ljudski mozak, sposobna da prenosi elektrohemski signal. Ćelija se sastoji od tijela (soma) koje u svom centru poseduje jezgro (nukleus), razgranate ulazne strukture (dendroni) i izlaznu osu (akson). Akson jedne ćelije povezan je sa dendrom drugog. Sinapsa je funkcionalni međumembranski kontakt aksona jednog neurona i dendrona drugog (Slika 4.1). Kada je neuron aktiviran, on šalje elektrohemski signal preko aksona ka drugoj ćeliji i taj signal može biti promijenjen od strane sinapse koja je sposobna da poveća ili smanji snagu veze i time prouzrokuje aktiviranje druge ćelije ili njeno mirovanje. Dakle, neuron kao osnovna jedinica nervnog sistema, prima informacije od drugih neurona putem dendrita, obrađuje ih, a zatim šalje impuls putem aksona i sinapsi drugim neuronima u mreži.

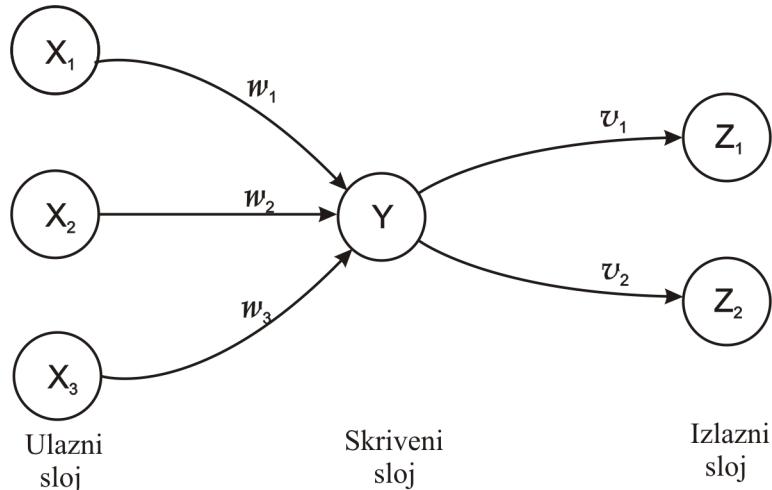


Slika 4.1- Struktura biološkog neurona

Vještački neuron prima ulazne signale analogne elektrohemskim impulsima i odgovara adekvatnim izlazom analogno izlazu biološkog neurona [14]. Sinapse su modelovane jednim brojem (težinom) kojim se svaki od ulaza množi prije slanja narednom vještačkom neuronu.

## 4.2 Arhitekture neuronskih mreža

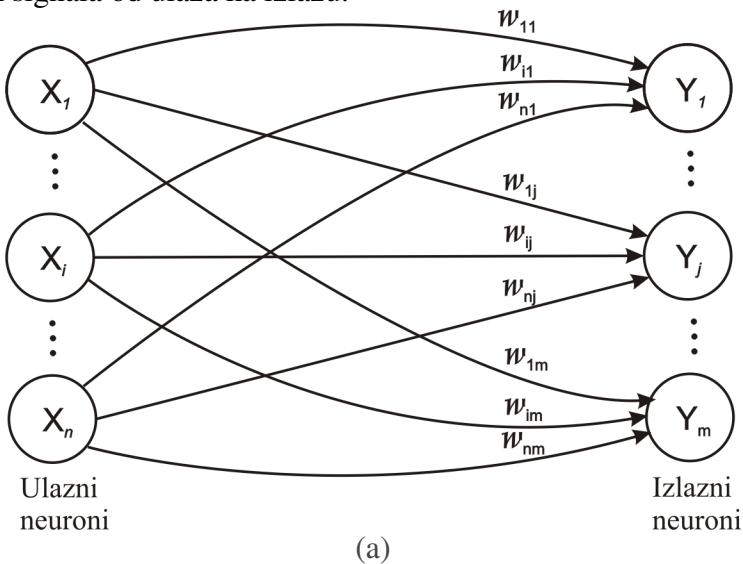
Raspored neurona u slojevima kao i pravilo povezivanja unutar i između slojeva se naziva arhitektura mreže [15]. Jednostavna mreža ilustrovana je na slici 4.2 koju čine neuroni ulaznog sloja, izlazni neuroni i jedan skriveni sloj.

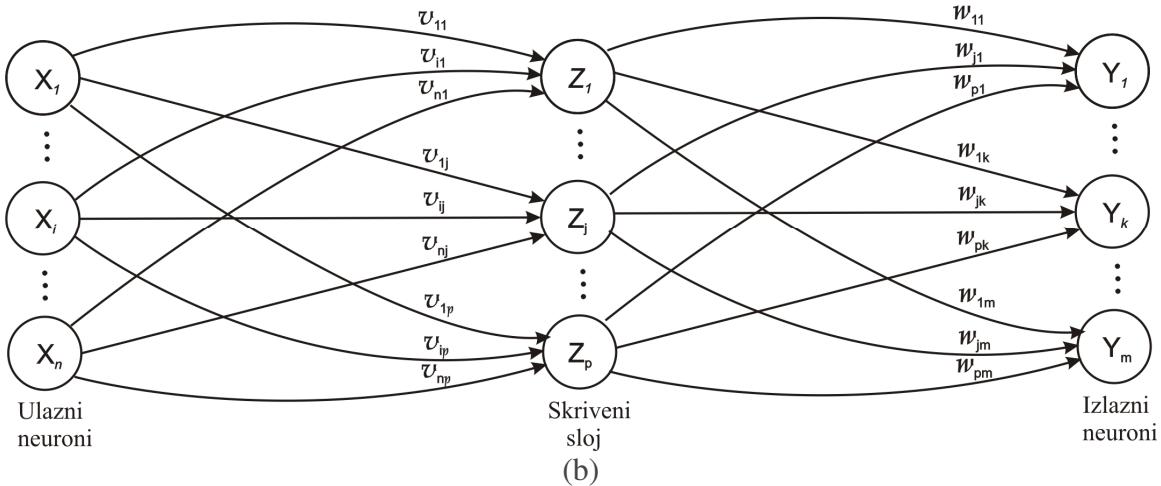


Slika 4.2 - Jednostavna neuronska mreža

Često se neuronske mreže klasificuju na jednoslojne ili višeslojne. U određivanju broja slojeva ulazni sloj se ne računa kao sloj jer ne utiče težinski na ulazne signale tj. ne vrši multiplikaciju ulaznih signala. Isto tako, broj slojeva u mreži se može definisati kao broj slojeva koje karakterišu težinske veze između neurona. Ova definicija je više zastupljena zbog važnosti težinskih faktora u teoriji neuronskih mreža uopšte. Mreža na slici 4.2 ima dva sloja.

Višeslojne mreže, po cijenu otežavanja procesa treniranja, mogu riješiti kompleksnije probleme u odnosu na jednoslojne, kod kojih za određene probleme ne postoji čak ni mogućnost da se korektno istreniraju. O pojmu trening i načinima treniranja (učenja) će biti više riječi u slijedećem paragrafu. Jednoslojna mreža i višeslojna mreža prikazane na Slici 4.3 predstavljaju primjer tzv. feed-forward mreža – mreže čiji je tok signala od ulaza ka izlazu.





Slika 4.3 - Primjer jednoslojne (a) i dvoslojne/višeslojne (b)neuronske mreže

Za razliku od feed-forward mreža postoje i rekurentne mreže tzv. feed-back mreže kod kojih signali mogu da putuju u oba smjera. Ulagani atributi moraju proći mrežu više od jednog puta prije nego što se proizvede odgovor. Ovakve strukture koriste se za rješavanje dinamičkih, kompleksnih problema, ali mogu da postanu vrlo komplikovane i da iziskuju mnogo vremena za podešavanje. Stanje ovih mreža mijenja se dok ne dostignu tačku ravnoteže. Ostaju u ravnotežnom stanju sve dok se ne pojavi novi ulaz i tada se vrši ponovna adaptacija i pronalaženje ravnotežnog stanja. Obično im je potrebno duže vrijeme da daju izlaz u odnosu na feed-forward mreže.

### 4.3 Algoritmi učenja

Pored arhitekture mreža, veoma važna karakteristika neuronskih mreža je metoda kojom se prilagođavaju težinski faktori tj. trenira mreža. Razlikuju se dva tipa treniranja – nadgledano i nenadgledano učenje.

U procesu nadgledanog učenja za svaki trening vektor je poznat željeni izlagani vektor, pa se razlika željenog i izračunatog izlaza koristi za korekciju težina neuronske mreže. Bitno pitanje koje se tiče ovog tipa učenja je problem minimiziranje razlike između dobijenog i željenog izlaza.

### 4.4 Nenadgledano učenje

Nenadgledano učenje implementiraju tzv. SOM neuronske mreže koje grupišu „slične“ ulazne vektore bez prethodne specifikacije kriterijuma raspodjele ulaznih vektora po klasama. Dakle samo-organizujuće mreže se treniraju samo na osnovu ulaznih podataka, bez definisanih željenih izlaganih vektora za adaptaciju težina mreže, već se korekcija težina vrši tako da su najsličniji ulazni vektori dodijeljeni istoj klasi na izlazu.

Kohonenova samo-organizujuća mapa, o kojoj će u narednom dijelu glave biti više riječi, na ovom principu vrši klasterizaciju ulaznih vektora.

Dalje neće biti ulaženo u pojednosti pomenutih tipova neuronskih mreža, već će najviše pažnje biti posvećeno tipu mreža SOM i LVQ koje su korištene kao klasifikatori u praktičnom dijelu rada.

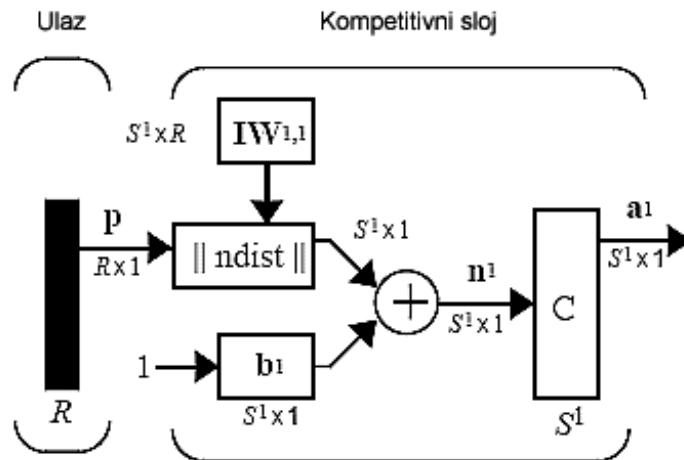
Spomenuto je da se kod nadgledanog učenja podrazumijeva da su trening podaci korišteni za formiranje klasifikatora labelisani po pripadnosti klasi[16]. Postoji dosta razloga u korist nenadgledanih procedura učenja, a neki od tih su:

- Prikupljanje i labelisanje velikog skupa uzoraka može biti iznenađujuće finansijski neisplativo. Na primjer, snimanje govora je relativno jeftino, ali ispravno labelisanje govora – označavanje riječi ili fonema u zvučnom zapisu može biti veoma skupo i vremenski neefikasno.
- U velikim aplikacijama za pronalaženje podataka (eng. data mining) gdje sadržaj velikih baza podataka nije poznat, veoma je korisno pristupiti klasifikaciji uz pomoć nenadgledanog učenja, a nakon toga koristiti nadgledanu proceduru.
- Nenadgledana procedura se može pokazati veoma korisnom i u dobijanju osnovnih informacija o strukturi i prirodi podataka u velikoj bazi.

#### 4.4.1 Kompetitivno učenje

Iako kompetitivno učenje nije direktno korišteno u radu, bitno je objasniti koncepte tog načina učenja jer se naredna objašnjenja baziraju na njemu. Razmatranje će biti praćeno uz objašnjenje Matlab funkcija [17].

Neuroni u kompetitivnom sloju/mreži se tako raspoređuju (distribuiraju) kako bi mogli prepoznati ulazne vekore. Arhitektura kompetitivnih mreža je prikazana na slijedećoj slici.



Slika 4.4 – Arhitektura kompetitivne mreže

Posmatra se kompetitivna mreža sa  $S^1$  neurona. Blok  $\|ndist\|$  prihvata ulazni vektor  $\mathbf{p}$ , dimenzija  $R \times 1$  i ulaznu matricu težina  $\mathbf{IW}^{1,1}$ , dimenzija  $S^1 \times R$ , te na izlazu daje

vektor sa  $S^1$  elemenata. Ti elementi su negativne distance između ulaznog vektora i redova ulazne matrice težina  $\mathbf{IW}^{1,1}$ .

Ulaz mreže  $\mathbf{n}^1$  kompetitivnog sloja je izračunat nalaženjem negativne distance između ulaznog vektora  $\mathbf{p}$  i težinskih vektora, te dodavanjem vektora korekcije  $\mathbf{b}^1$ . Uloga vektora korekcije će biti objašnjena kasnije. Ako su svi elementi vektora korekcije nula, maksimalni ulaz u mrežu koji prima neuron će biti 0. Ovo nastaje kada je ulazni vektor  $\mathbf{p}$  izjednačen sa težinskim vektorom neurona.

Kompetitivna funkcija C prihvata ulazni vektor mreže za određeni sloj i vraća 0 na izlazima neurona za sve neurone osim za pobjednika, neurona koji odgovara na najpozitivniji element ulaza mreže  $\mathbf{n}^1$ . Izlaz pobjednika je 1. Ako su svi elementi vektora korekcije 0, onda neuron čiji je težinski vektor najbliži ulaznom vektoru ima najmanje negativan mrežni ulaz i prema tome pobijeđuje u odnosu na konkurenciju i na svom izlazu daje 1.

Težine pobjedničkog neurona (jedan od redova ulazne težinske matrice) su nakon opisanog prvog koraka učenja korigovani pomoću Kohonenovog pravila učenja (4.1). Prepostavljajući da i-ti neuron pobijedi, elementi i-tog reda ulazne matrice težina  $\mathbf{IW}^{1,1}$  su korigovane prema sljedećem izrazu:

$$i\mathbf{IW}^{1,1}(q) = i\mathbf{IW}^{1,1}(q-1) + \alpha(p(q) - i\mathbf{IW}^{1,1}(q-1)) \quad (4.1)$$

Kohonenovo pravilo omogućava korekciju težina neurona prema ulaznom vektoru što se naziva proces učenja. Baš iz ovog razloga je ovo pravilo korisno u aplikacijama prepoznavanja uzorka. Dakle, neuron čiji je težinski vektor bio najbliži ulaznom vektoru je korigovan da bude još bliže. Sad će vjerovatnoća da isti neuron pobijedi biti još veća, ukoliko je novi ulazni vektor sličan ovom razmatranom, a vjerovatnoća da pobijedi za drugačiji ulazni vektor će biti dodatno smanjena. Kako se sve više i više ulaznih vektora dovodi, svaki neuron u sloju koji je najbliži grupi ulaznih vektora veoma brzo koriguje težinske vektore bliže tim ulaznim vektorima. Konačno, ako ima dovoljno neurona, svaki klaster sličnih ulaznih vektora će imati neuron koji na izlazu daje 1 kada je vektor iz klastera doveden, a 0 u svim ostalim slučajevima. Prema tome, kompetitivna mreža uči da kategorizuje dovedene ulazne vektore. Za realizaciju Kohonenovog pravila učenja korištena je funkcija *learnk* iz Matlab Neural Network toolboxa.

Jedno od ograničenja kompetitivne mreže je da će neki neuroni ostati nelocirani. Drugim riječima, težinski vektor nekog neurona može zauzeti poziciju veoma daleko od bilo kog ulaznog vektora i samim tim nikad pobijediti u nadmetanju (eng. competition), bez obzira koliko dugo trening traje. Posljedica toga je da njihove težine neće biti podvrgnute procesu učenja i korekciji. Ovi „nesrećni“ neuroni, često nazivani mrtvi neuroni, nikad ne budu iskorišteni. Da bi se ovo sprječilo, korišteni su vektori korekcije da daju prednost neuronima koji pobijeđuju u nadmetanju rijetko (ili nikad) u odnosu na neurone koji često pobijeđuju. Pozitivni elementi vektora korekcije, dodani na negativne distance prouzrokuje povećanu vjerovatnoću da daleki neuron pobijedi.

Pomoću Matlab funkcije *learncon* vrijednosti elemenata vektora korekcije se koriguju tako da za često aktivne neurone oni postaju manji, a za manje aktivne postaju veći. Kako se elementi vektora korekcije manje aktivnih neurona povećavaju, ulazni prostor na koji ti neuroni odgovaraju se povećava. Kako se ulazni prostor povećava, manje aktivni neuroni odgovaraju i pomjeraju se prema ulaznim vektorima. Na posljetku će do sad zanemarivani neuron odgovarati na jednak broj vektora kao i ostali neuroni.

Ovo ima dobar efekat. Prvo, ako neuron nikad ne pobijedi u nadmetanju jer su njegove težine daleko od ulaznih vektora, njegov vektor korekcije će vremenom postati dovoljno velik tako da će on biti u mogućnosti da pobijedi. Kad se ovo desi, neuron će biti pomjeren ka određenoj grupi vektora. Kad se počne dešavati da taj neuron konstantno pobjeđuje, njegov vektor korekcije će se smanjiti na nulu. Ovim je problem mrtvih neurona riješen.

#### 4.4.2 SOM mreža

SOM mapa je tip vještačke neuronske mreže koja je trenirana korištenjem nenadgledanog učenja. Na svom izlazu daje niskodimenzionalnu diskretizovanu reprezentaciju (mapu) ulaznog prostora uzoraka za treniranje koji je često višedimenzionalan. Cilj je da se svi vektori ulaznog prostora predstave u niskodimenzionalnoj mapi, ali tako da se udaljenosti između vektora očuvaju. Model je prvi put opisan kao vještačka neuronska mreža od strane Finskog profesora Tuevo Kohonena i iz tog razloga se često sreće pod nazivom Kohonenova mapa [18].

SOM uče da klasifikuju ulazne vektore prema njihovoj raspoređenosti u ulaznom prostoru. One se razlikuju od kompetitivnih slojeva u tome što se i susjedni neuroni pored neurona pobjednika u samoorganizujućim mapama treniraju da izdiferenciraju susjedne sekcije prostora ulaznih vektora. Prema tome, samoorganizujuće mape uče i raspored (kao kompetitivni slojevi) i topologiju ulaznih vektora korištenih za trening.

Neuroni u sloju SOM mape su tako pozicionirani da odgovaraju fizičkim pozicijama prema određenoj topološkoj funkciji. Matlab funkcije *gridtop*, *hextop*, ili *randtop* pozicioniraju neurone na kvadratnu, heksagonalnu ili slučajnu topologiju (mrežu). Udaljenosti neurona su proračunate na osnovu funkcije distance, a u Matlabu su specificirane četiri funkcije distance: *dist*, *boxdist*, *linkdist* i *mandist*.

Pobjednički vektor  $i^*$  u SOM mapi se određuje korištenjem iste procedure kao kod kompetitivnog sloja. Ipak, umjesto korekcije samo pobjedničkog neurona, svi neuroni unutar susjedstva  $N_{i^*}(d)$  se koriguju koristeći Kohonen pravilo. Težine neurona  $i \in N_{i^*}(d)$  se koriguju prema jednačini (4.2) ili (4.3).

$$_i\mathbf{w}(q) = _i\mathbf{w}(q-1) + \alpha(\mathbf{p}(q) - _i\mathbf{w}(q-1)) \quad (4.2)$$

tj.

$$_i\mathbf{w}(q) = (1-\alpha)_i\mathbf{w}(q-1) + \alpha\mathbf{p}(q), \quad (4.3)$$

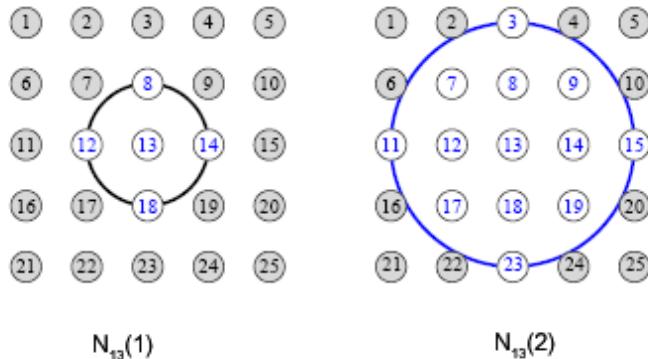
gdje su  $_i\mathbf{w}(q)$  težina  $i$ -tog neurona u  $q$ -toj iteraciji,  $_i\mathbf{w}(q-1)$  težina  $i$ -tog neurona u iteraciji prije  $q$ ,  $\mathbf{p}(q)$  ulazni vektor i  $\alpha$  koeficijent učenja (eng. learning rate).

Susjedstvo  $N_{i^*}(d)$  podrazumijeva korekciju težina neurona koji se nalaze unutar radijusa  $d$  odnosu na pobjednički neuron  $i^*$ :

$$N_{i^*}(d) = \{j, d_{ij} \leq d\} \quad (4.4)$$

Prema tome, kad je vektor  $\mathbf{p}$  na ulazu, težine pobjedničkog neurona i njemu susjednih se pomjeraju prema vektoru  $\mathbf{p}$ . Nakon nekog vremena treniranja susjedni neuroni nauče jednako odgovarati na vektore koji su slični.

Radi ilustracije koncepta susjedstva, data je Slika 4.5. Lijevi dijagram pokazuje dvodimenzionalno susjedstvo radijusa  $d = 1$  oko neurona sa oznakom 13, dok desni dijagram pokazuje susjedstvo u radijušu od  $d = 2$ .



Slika 4.5 – Dvodimenzionalno susjedstvo radijusa  $d = 1$  označeno sa  $N_{13}(1)$  i radijusa  $d = 2$  označeno sa  $N_{13}(2)$

Susjedstva  $N_{13}(1)$  i  $N_{13}(2)$  su definisana na slijedeći način:

$$N_{13}(1) = \{8, 12, 13, 14, 18\} \text{ i} \quad (4.5)$$

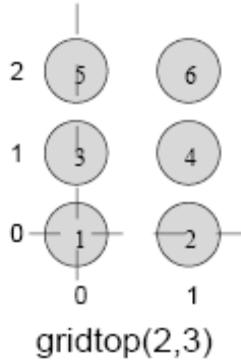
$$N_{13}(2) = \{3, 7, 8, 9, 11, 12, 13, 14, 15, 17, 18, 19, 23\} \quad (4.6)$$

Neuroni u SOM ne moraju biti postavljeni u dvodimenzionalnu mrežu. Može se koristiti jednodimenzionalni raspored ili čak tri ili više dimenzija. Za jednodimenzionalnu SOM, neuron ima samo dva susjeda u radijušu 1 (ili jednog susjeda ako se neuron nalazi na ivici). Može se takođe definisati udaljenost na različite načine, korištenjem pravougaonog ili heksagonalnog rasporeda neurona, dok treba imati na umu da performanse sistema ne zavisi od konkretnog oblika susjedstva.

Gridtop toplogija inicijalizuje pozicije neurona po pravougaonoj strukturi. Ako je potrebno realizovati 2x3 mrežu neurona, može se pisati:

```
pos = gridtop(2, 3)
pos =
    0      1      0      1      0      1
    0      0      1      1      2      2
```

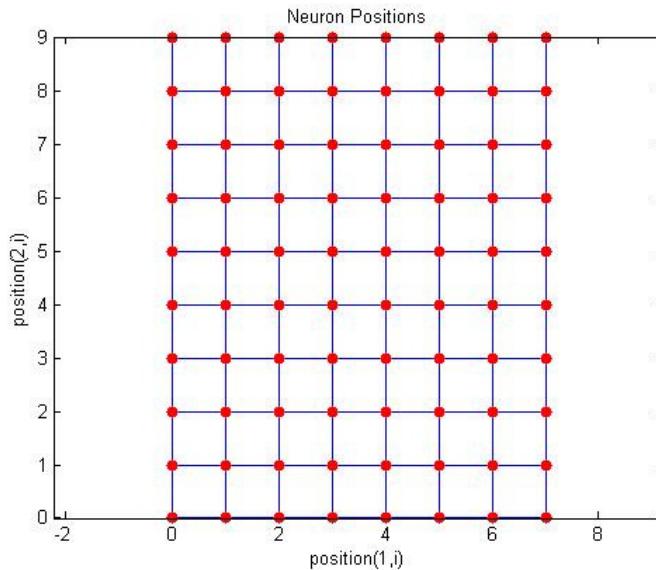
Neuron 1 u ovom slučaju ima poziciju (0,0), neuron 2 poziciju (1,0), neuron 3 poziciju (0,1) itd. kao na slici 4.6.



Slika 4.6 – Ilustracija rasporeda neurona pomoću gridtop Matlab funkcije

*Gridtop* topologija neurona dimenzija  $8 \times 10$  jednostavno se kreira i iscrtava u MATLAB-u sljedećim kodom:

```
pos = gridtop(8,10);
plotsom(pos)
```



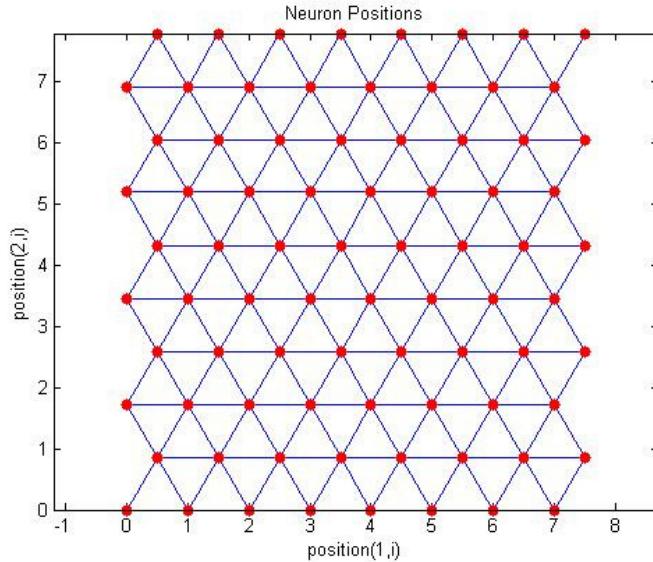
Slika 4.7 – Ilustracija rasporeda neurona u mreži  $8 \times 10$  pomoću gridtop Matlab funkcije

*Hextop* funkcija kreira heksagonalni (šestougaoni) raspored neurona, a kreiranje  $2 \times 3$  mreže neurona je ostvareno na sljedeći način:

```
pos = hextop(2,3)
pos =
    0      1.0000      0.5000      1.5000      0      1.0000
    0          0      0.8660      0.8660     1.7321     1.7321
```

Kreiranjem neuronske mreže funkcijom *newsom*, ukoliko se ne specificira željeni inicijalni raspored neurona, podrazumijeva se *Hextop* funkcija. *Hextop* topologija neurona dimenzija  $8 \times 10$  jednostavno se kreira i iscrtava u MATLAB-u sljedećim kodom:

```
pos = hextop(8,10);
plotsom(pos)
```



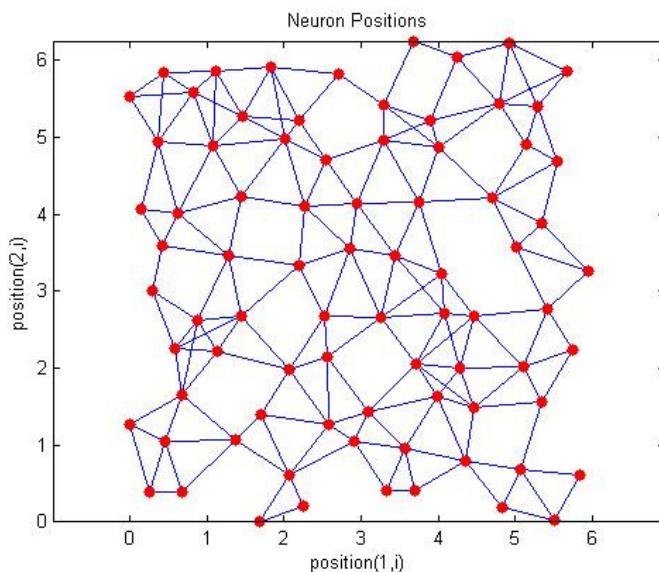
Slika 4.8 – Ilustracija rasporeda neurona u mreži 8x10 pomoću *hextop* Matlab funkcije

Funkcija *randtop* kreira neurone raspoređujući ih po n-dimenzionalnoj slučajnoj topologiji. Sljedeći kod generiše random strukturu neurona:

```
pos = randtop(2, 3)
pos =
    0      0.7620      0.6268      1.4218      0.0663      0.7862
    0.0925          0      0.4984      0.6007      1.1222      1.4228
```

*Randtop* topologija neurona 8x10 veličine se kreira slijedećim kodom:

```
pos = randtop(8, 10);
plotsom(pos)
```



Slika 4.9 – Ilustracija rasporeda neurona u mreži 8x10 pomoću *randtop* Matlab funkcije

Matlab Neural Network toolbox omogućava četiri načina kalkulacije distance između neurona.

Funkcija *dist* izračunava Euklidsku distancu između neurona, pa za, na primjer, tri neurona:

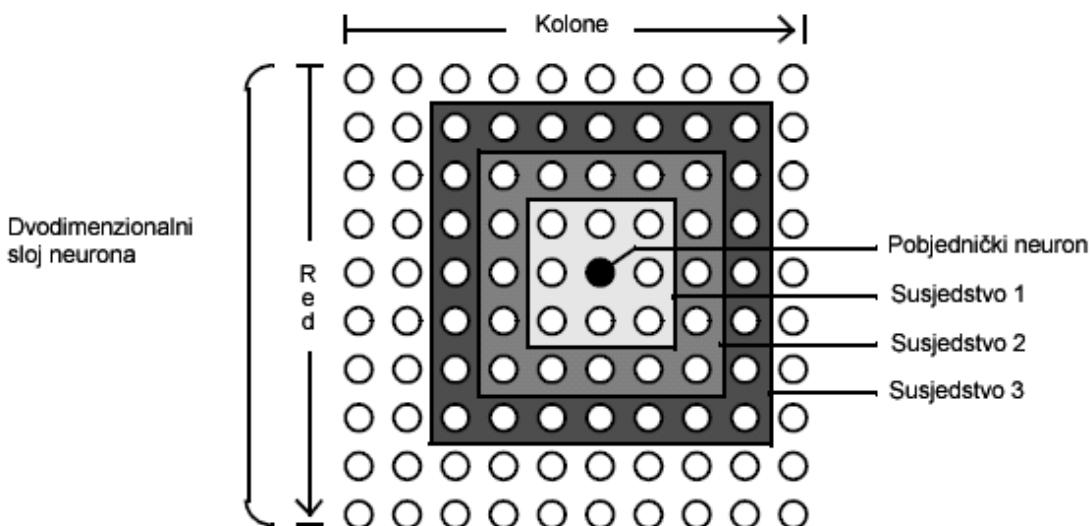
```
pos2 = [ 0 1 2; 0 1 2]
pos2 =
    0      1      2
    0      1      2
```

Distanca se pronađe slijedećom MATLAB funkcijom:

```
D2 = dist(pos2)
D2 =
    0      1.4142    2.8284
    1.4142      0      1.4142
    2.8284    1.4142      0
```

Dakle, distanca od neurona 1 na poziciji (0,0) do sebe samog je nula, dok distanca od neurona 1 do neurona 2 na poziciji (1,1) iznosi  $\sqrt{2}$ .

Slika 4.10 prikazuje kvadratnu mrežu neurona u dvije dimenzije. Susjedstva su označena različitim nijansama sive na slici, a susjedstvo radijusa 1 obuhvata središnji neuron i najbliže neurone, dok susjedstvo dijametra 2 obuhvata neurone iz susjedstva dijametra 1 i njihove najbliže neurone.

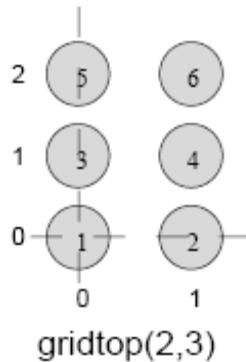


Slika 4.10 – Ilustracija susjedstva u dvodimenzionalnom sloju neurona

Kod *dist* funkcije, distance sloja sa  $S$  neurona su predstavljene  $S \times S$  matricom udaljenosti. Prethodna slika sa udaljenostima dijametra 1 i 2 je dobijena korištenjem *boxdist* funkcije, o kojoj će biti malo kasnije riječi.

Radi boljeg razumijevanja navodi se slijedeći primjer sa 6 neurona u *gridtop* konfiguraciji:

```
pos = gridtop(2,3)
pos =
    0      1      0      1      0      1
    0      0      1      1      2      2
```



Slika 4.11 – Konfiguracija 6 neurona dobijena *gridtop* funkcijom

Za navedeni sloj neurona *box* distance se dobiju na sljedeći način (dat je i rezultat za konkretni primjer):

`d = boxdist(pos)`

`d =`

0	1	1	1	2	2
1	0	1	1	2	2
1	1	0	1	1	1
1	1	1	0	1	1
2	2	1	1	0	1
2	2	1	1	1	0

Udaljenost od neurona 1 sa pozicije (0,0) do neurona 2(1,0), 3(0,1) i 4(1,1) iznose 1, distance do neurona 5(0,2) i 6(1,2) iznose 2. Distance od neurona 3 i 4 do ostalih neurona iznosi samo 1.

Link distanca od jednog neurona je broj veza ili koraka koji se moraju napraviti da bi se došlo do željenog neurona. Prema tome, ako se računaju distance od neurona sa slike uz pomoć *linkdist*, dobija se sljedeća matrica distanci:

`dlink =`

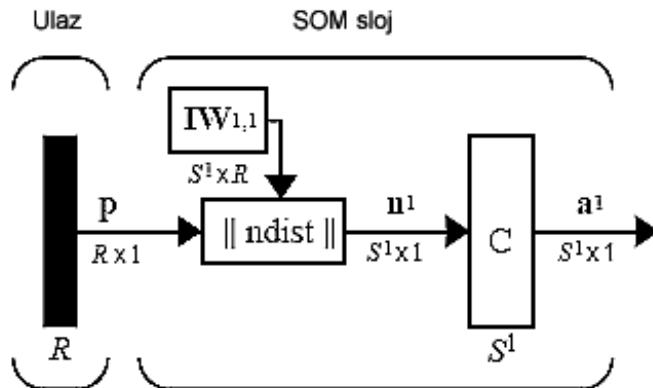
0	1	1	2	2	3
1	0	2	1	3	2
1	2	0	1	1	2
2	1	1	0	2	1
2	3	1	2	0	1
3	2	2	1	1	0

Manhattan distanca između vektora  $x$  i  $y$  se računa na sljedeći način:

$$D = \sum |x - y|, \quad (4.7)$$

funkcija kojom se pomenuta metrika realizuje u MATLAB-u se naziva *mandist*.

Arhitektura SOM mreže je data na Slici 4.12.



Slika 4.12 – Arhitektura SOM mreže

Arhitektura je slična kompetitivnoj mreži, s tim što se ovdje ne koriste vektori korekcije. Elementi vektora na izlazu  $\|ndist\|$  bloka se računaju kao kod kompetitivnih mreža na slijedeći način:

$$\mathbf{n}_i^1 = -\|_i \mathbf{IW}^{1,1} - \mathbf{p}\|, \quad (4.8)$$

dok za izlazni vektor iz kompetitivne funkcije C (označene sa *compet*) vrijedi:

$$\mathbf{a}^1 = \text{compet}(\mathbf{n}^1) \quad (4.9)$$

Kompetitivna transfer funkcija na izlazu elementa  $\mathbf{a}_i^1$  koji odgovara pobjedničkom neuronu  $i^*$  daje vrijednost 1. Svi ostali izlazni elementi u  $\mathbf{a}^1$  su postavljeni na 0.

Težine neurona čije su pozicije bliske pobjedničkom neuronu su korigovane zajedno sa težinama pobjedničkog neurona. Kao što je i pokazano, u Matlabu se mogu izabrati različite topologije neurona, a isto tako, se mogu i izabrati različite metrike za određivanje koji su to neuroni bliski pobjedničkom i čije će se težine korigovati.

Kreiranje nove SOM mreže je omogućeno pomoću funkcije *newsom*, čija realizacija se zasniva na četiri parametra:

- Koeficijent učenja u fazi raspoređivanja (eng. Ordering-phase learning rate)
- Broj koraka u fazi raspoređivanja (eng. Ordering-phase steps)
- Koeficijent učenja u fazi korekcije (eng. Tuning-phase learning rate)
- Veličina dijametra susjedstva u fazi korekcije (eng. Tuning-phase neighborhood distance)

Ove vrijednosti su korištene za trening i adaptaciju.

Za svaki ulazni vektor pojedinačno, mreža počinje identifikacijom pobjedničkog neurona. Tada se težine pobjedničkog neurona i ostalih neurona u susjedstvu koriguju i neuroni se pomjeraju bliže ulaznim vektorima sa svakim korakom učenja, koristeći Matlab funkciju *learnsom*, funkciju učenja za SOM. Težine pobjedničkog neurona su korigovane proporcionalno koeficijentu učenja prema jednačini (4.1). Težine neurona u susjedstvu pobjedničkog su korigovane proporcionalno polovini koeficijenta učenja. Pomoću radijusa susjedstva određuju se neuroni koji pripadaju oblasti oko pobjedničkog neurona i kojima će se korigovati težine koeficijentom učenja. Proces učenja se može razdvojiti u dvije faze, prvu fazu - fazu raspoređivanja i drugu fazu - fazu fine korekcije.

Kod faze raspoređivanja dužina trajanja faze je određena unaprijed definisanim brojem koraka. Radijus susjedstva počinje od vrijednosti najveće udaljenosti između dva neurona i opada do radijusa koji se koristi u drugoj fazi – fazi fine korekcije. Koeficijent

učenja počinje od vrijednosti definisane u prvoj fazi i opada dok ne dostigne koeficijent učenja faze fine korekcije. Kako dijametar susjedstva i koeficijent učenja opadaju tokom prve faze tako se neuronimreže postavljaju u ulaznom prostoru prema istoj topologiji kojom su raspoređeni fizički.

Kod faze fine korekcije dijametar susjedstva ostaje na vrijednosti dijametra koju je mreža imala na početku ove faze (što bi trebalo da uključuje samo najbliže susjede – tipično 1). Koeficijent učenja nastavlja da veoma sporo opada od vrijednosti sa početku faze. Mali dijametar susjedstva i sporo opadajući koeficijent učenja vrše finu korekciju težina, održavajući globalnu sliku neurona stabilnom. Broj epoha druge faze treniranja tj. broj ponavljanja druge faze treniranja trebao bi biti dosta veći od broja koraka faze raspoređivanja jer faza fine korekcije uobičajeno zahtjeva više vremena.

U narednoj tabeli su date tipične vrijednosti specifičnih veličina u fazi treniranja, a te vrijednosti se koriste u Matlab funkciji *learnsom* ukoliko drugačije nije navedeno. LP u tabeli stoji kao skraćenica za fazu učenja (eng. Learning Phase).

Tabela 4.1 – Tipične vrijednosti specifičnih veličina u fazi treniranja (za Matlab)

LP.order_lr	0.9	Koeficijent učenja u fazi raspoređivanja
LP.order_steps	1000	Broj koraka u fazi raspoređivanja
LP.tune_lr	0.02	Koeficijent učenja u fazi fine korekcije
LP.tune_nd	1	Dijametar susjedstva u fazi fine korekcije

Dakle, konkretno posmatrajući konfiguraciju procesa treniranja SOM mape u Matlabu, koeficijent učenja LR (eng. Learning Rate) i dijametar susjedstva ND (eng. Neighborhood Distance) se koriguju kroz dvije faze: fazu raspoređivanja i fazu fine korekcije. Trajanje faza raspoređivanja je definisano brojem koraka LP.order\_steps. Tokom ove faze LR je korigovan od LP.order\_lr do LP.tune\_lr i ND je korigovan sa maksimalne udaljenosti na 1. U toku ove faze se težine neurona raspoređuju u ulaznom prostoru konzistentno sa pozicijom neurona.

Tokom faze fine korekcije LR opada polako sa LP.tune\_lr, a ND je fiksiran na LP.tune\_nd. Tokom ove faze težine se raspoređuju po ulaznom prostoru održavajući topologiju sa završetka faze raspoređivanja.

Prema tome, vektori težina neurona inicijalno koriste velike korake korekcije pomjerajući se tako brže ka području gdje se pojavljuju ulazni vektori. Jednom kad se dijametar susjedstva dovede na vrijednost 1, mreža bi trebala biti dobro raspoređena prema topološkim pozicijama ulaznih vektora u prostoru obilježja dajući još vremena neuronima da se finije rasporede oko ulaznih neurona pomoću sporo opadajućeg koeficijenta učenja.

Kao i kod kompetitivnih slojeva, neuroni SOM mape će se rasporediti sa približno jednakim međusobnim distancama unutar određene sekcije ako se ulazni vektori pojavljuju sa podjednakom vjerovatnoćom unutar te sekcije ulaznog prostora. Ako su ulazni vektori po ulaznom prostoru raspoređeni po sekcijama i sa neravnomjernim

brojem vektora po sekciji, neuroni sloja samoorganizujuće mape teže da se rasporede prema odnosu pojavljivanja broja ulaznih vektora po sekcijama.

Dakle, SOM mape treniranjem, pored sposobnosti da kategorisu ulazne vektore, dobijaju i sposobnost da nauče topologiju i distribuciju ulaznih vektora.

Definisanjem broja epoha definiše se broj iteracija treniranja, a kod u Matlabu za definisanje 1000 epoha za neku konkretnu mrežu izgleda ovako:

```
net.trainParam.epochs = 1000;
net = train(net,P);
```

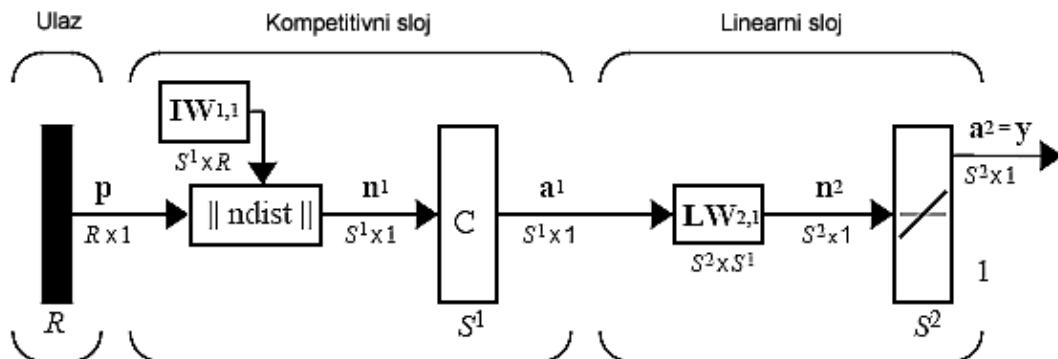
Zaključak je da se SOM mape razlikuju od konvencionalnog kompetitivnog učenja po načinu korigovanja težina neurona. Umjesto korigovanja težine samo neurona pobjednika, ove mreže koriguju težine kako neurona tako i njegovih susjeda. Rezultat je aktiviranje susjednih neurona na „slične“ ulazne vektore.

## 4.5 LVQ mreža

LVQ mreža se obučava nadgledano. Ona se može prihvati kao specijalan slučaj vještačke neuronske mreže i on se bazira na pobjednik-odnosi-sve (eng. winner-takes-all) principu učenja gdje se na ulazni vektor aktivira određena grupa izlaznih neurona koja vremenom postaje sve manja i manja da bi na kraju učenja samo jedan neuron izlaznog sloja bio aktivan [18]. Mreža se sastoji od tri sloja: ulazni sloj, Kohonenov kompetitivni sloj i linerani izlazni sloj o čemu će biti više riječi u daljem tekstu.

LVQ algoritam se često koristi da dodatno poboljša klasterizaciju preuzetu sa izlaza Kohonenove samo-organizujuće mape oslanjajući se na izlazne neurone mape koji nakon labelisanja predstavljaju centroide različitih klasa ulaznih vektora. Fino podešavanje klasifikacije koje obavlja LVQ ustvari koriguje granice klasa nakon labelisanja klastera i grupisanja u klase.

Arhitektura LVQ mreže je data na slici 4.13.



Slika 4.13 – Arhitektura LVQ mreže

gdje su:

$R$  – broj elemenata ulaznog vektora  
 $S^1$  – broj kompetitivnih neurona  
 $S^2$  – broj linearnih neurona

LVQ mreža ima prvi kompetitivni sloj i drugi linearne slojeve. Kompetitivni sloj klasterizuje ulazne vektore na način kako je već prethodno objašnjeno. Linearni sloj transformiše klase kompetitivnog sloja u željenu klasifikaciju koju je definisao korisnik. U daljem tekstu će se klase na izlazu kompetitivnog sloja nazivati *potklase*, a klase linearanog sloja *željene klase*.

Kompetitivni sloj može da klasifikuje do  $S^1$  potklasa, dok na izlazu linearnog sloja može da se dobije  $S^2$  željenih klasa. Za demonstraciju zavisnosti željenih izlaznih klasa linearnog sloja i potklasa kompetitivnog sloja poslužiće sljedeći primjer. Ako se pretpostavi da neuroni 1, 2 i 3 kompetitivnog sloja pripadaju potklasama koje konačno pripadnu klasi 2 nakon linearnog sloja, kompetitivni neuroni 1, 2, 3 će imati  $LW^{2,1}$  težine vrijednosti 1 za neuron  $n^2$  linearnog sloja, a težine 0 za sve ostale neurone. Prema tome, linearni neuron  $n^2$  koji odgovara izlaznoj klasi 2 je aktiviran i daje na izlazu 1 ako bilo koji od tri kompetitivna neurona 1, 2 ili 3 pobijedi. Ukratko, 1 u  $i$ -tom redu vektora  $\mathbf{a}^1$  (ostali elementi  $\mathbf{a}^1$  su 0) odabira  $i$ -tu kolonu matrice  $LW^{2,1}$  kao izlaz mreže. Svaka kolona te matrice sadrži po jednu jedinicu koja odgovara određenoj klasi.

LVQ mreža pomoću programskog paketa Matlab se može kreirati korištenjem funkcije *newlvq*, na slijedeći način:

```
net = newlvq(PR, S1, PC, LR, LF),
```

gdje je:

$PR$  – Rx2 matrica minimalnih i maksimalnih vrijednosti  $R$  ulaznih elemenata

$S1$  – broj skrivenih neurona prvog sloja

$PC$  – vektor procenata ulaznih elemenata po klasama

$LR$  – koeficijent učenja (ako se ne navede uzima se 0.01)

$LF$  – funkcija učenja (definiše Matlab funkciju za željeni tip LVQ algoritma)

LVQ1 algoritam nije jedini tip LVQ algoritma koji se koristi. Međutim kako je u radu korišten LVQ1 ostali neće biti opisivani. LVQ učenje je bazirano na parovima ulazni-željeni vektor. Za određeni ulazni vektor  $\mathbf{p}_i$  željeni vektor  $\mathbf{t}_i$  ima samo jedan element koji je jednak 1, dok su ostali 0 što određuje klasifikaciju tog ulaznog vektora.

$$\{\mathbf{p}_1, \mathbf{t}_1\}, \{\mathbf{p}_2, \mathbf{t}_2\}, \dots, \{\mathbf{p}_Q, \mathbf{t}_Q\} \quad (4.10)$$

Ulagani vektori su označeni sa  $\mathbf{p}$ , a željeni sa  $\mathbf{t}$ .

U procesu učenja, prihvata se ulazni vektor  $\mathbf{p}$ , izračunavaju se distance između  $\mathbf{p}$  i svakog reda ulazne težinske matrice  $IW^{1,1}$  pomoću Matlab funkcije *ndist*, nakon čega se neuroni skrivenog kompetitivnog sloja natječu. Pretpostavimo da je  $i$ -ti element  $\mathbf{n}^1$  najpozitivniji i da je neuron  $i^*$  pobjednik. Onda kompetitivna transfer funkcija proizvodi 1 kao  $i$ -ti element  $\mathbf{a}^1$ , dok su svi ostali elementi  $\mathbf{a}^1$  nula.

Kad se  $\mathbf{a}^1$  multiplicira sa težinama linearnog sloja  $LW^{2,1}$  element sa vrijednošću 1 u  $\mathbf{a}^1$  odabire klasu, te je klasa  $k^*$  povezana sa konkretnim ulaznim vektorom. Prema tome,

mreža je dodijelila ulazni vektor  $\mathbf{p}$  klasi  $k^*$  i element  $a_{k^*}^2$  vektora  $\mathbf{a}^2$  će biti 1. Naravno, ova dodjela klasi može biti i loša, pa element  $t_{k^*}$  vektora  $\mathbf{t}$  može imati vrijednost ili 0 ili 1 u zavisnosti da li zaista ulazni vektor pripada klasi  $k^*$  ili ne.

Korekcija matrice  $\mathbf{IW}^{1,1}$  se vrši tako što se  $i^*$ -ti red pomijera bliže ulaznom vektoru  $\mathbf{p}$  ako je dodjeljena pripadnost klasi tačna ili se red udaljuje od  $\mathbf{p}$  vektora ukoliko dodjela nije tačna. Dakle, ako je  $\mathbf{p}$  ispravno klasifikovan tj.

$$(a_{k^*}^2 = t_{k^*} = 1), \quad (4.11)$$

nova vrijednost  $i^*$ -tog reda matrice  $\mathbf{IW}^{1,1}$  se izračunava na slijedeći način:

$${}_{i^*}\mathbf{IW}^{1,1}(q) = {}_{i^*}\mathbf{IW}^{1,1}(q-1) + \alpha(p(q) - {}_{i^*}\mathbf{IW}^{1,1}(q-1)). \quad (4.12)$$

S druge strane ukoliko  $\mathbf{p}$  nije korektno klasifikovan tj.

$$(a_{k^*}^2 = 1 \neq t_{k^*} = 0) \quad (4.13)$$

nova vrijednost  $i^*$ -tog reda matrice  $\mathbf{IW}^{1,1}$  se računa ovako:

$${}_{i^*}\mathbf{IW}^{1,1}(q) = {}_{i^*}\mathbf{IW}^{1,1}(q-1) - \alpha(p(q) - {}_{i^*}\mathbf{IW}^{1,1}(q-1)) \quad (4.14)$$

Neuron iz skrivenog sloja se pomoću ovih korekcija pomjera prema vektorima koji su dodijeljeni klasi za koju se formuluje potklasa u skrivenom sloju i ujedno udaljuje od vektora koji su dodijeljeni drugim klasama. Matlab funkcija koja implementira ovaj LVQ algoritam glasi *learnlv1*.

Dakle, LVQ mreža klasificuje ulazne vektore u željene klase koristeći kompetitivni sloj da nađe potklase ulaznih vektora nakon čega ulazne vektore dodjeljuje željenim klasama. Jedini zahtjev je da kompetitivni sloj mora da ima dovoljno neurona i da svaka klasa mora biti dodijeljena dovoljnom broju neurona.

## **5. IMPLEMENTACIJA I EVALUACIJA PERFORMANSI SISTEMA ZA SEGMENTACIJU VAZDUŠNIH SLIKA**

U ovoj glavi opisan je praktični pristup implementaciji i testiranju sistema za klasifikaciju uzoraka sa vazdušnih i satelitskih snimaka. Implementacija i testiranje su zasnovani na reprezentaciji blokova slika pomoću deskriptora teksture i metodi ocjenjivanja sličnosti opisanoj u prethodnim glavama. Slike su izdijeljenje na blokove veličine 128x128 piksela, a obilježje po kome se pronalazila obilježja, ocjenjivala sličnost blokova i određivala klasa blokova je tekstura. Princip klasifikacije blokova slike evaluiran na vazdušnim snimcima može se primjeniti i na satelitske snimke Zemljine površine.

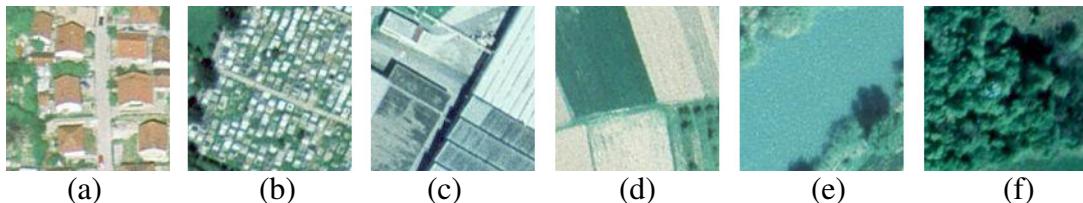
### **5.1 Implementacija**

#### **5.1.1 *Baza blokova slika***

Inicijalno, za evaluaciju performansi pretraživanja baze i pronalaženja sličnih slika na osnovu deskriptora teksture, korištena je Vision Texture baza slika tekstura sa 167 slika veličine 512x512 piksela [19]. Sve slika iz te baze imaju homogenu teksturu. Ova baza je pogodna za ocjenjivanje sposobnosti pronalaženja slika sa istom semantikom kao upit, jer su slike u Vision Texture bazi već anotirane u 20 klase, tako da nije bilo potrebno ručno anotiranje da bi se rezultati pretrage mogli evaluirati. Vision Texture baza pored slika veličine 512x512 sadrži slike u još 5 različitih veličina. Međutim, kako je sistem za segmentaciju vazdušnih slika zamišljen da radi sa blokovima ulaznih slika veličine 128x128 piksela, tako je bilo pogodno ograničiti se na dio baze sa slikama čije dimenzije odgovaraju cijelobrojnom umnošku broja 128. Pored toga, slike 512x512 piksela se dijele na 16 blokova veličine 128x128 piksela, pa prilikom testiranja uspješnosti pretraživanja one imaju prednost u odnosu na slike koje baš odgovaraju dimenzijama 128x128. Iz razloga što je sadržaj slika u Vision Texture bazi sa homogenom teksturom, u kreiranoj bazi se tako za svaku sliku dobija 16 blokova dimenzija 128x128 sa istim semantičkim sadržajem, pa se na blok upit za pretraživanje, uz taj blok, očekuje 15 blokova koji pripadaju istoj 512x512 piksela velikoj slici. Ovo je veoma korisno jer olakšava evaluaciju performansi pretraživanja baziranog na ekstrakciji deskriptora teksture. Rezultati su korišteni kao pokazni da se algoritam može prihvati kao osnova za razvijanje sistema za semantičku segmentaciju vazdušnih i satelitskih snimaka. Iz tog razloga nije bilo potrebe za statističkom obradom istih.

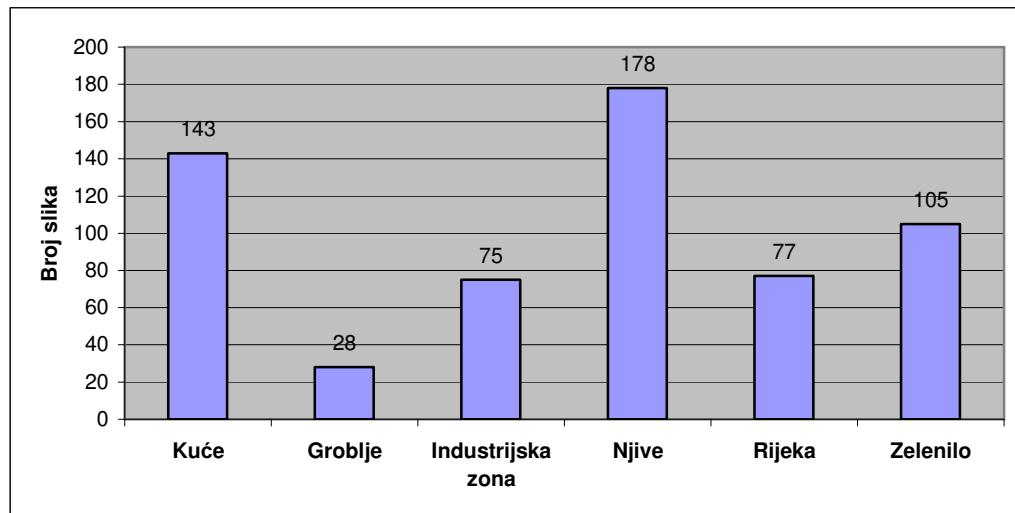
Druga baza korištena za testiranje sistema je formirana na osnovu blokova vazdušnih slika regije Banja Luka. Ortofotografije u omjeru 1:5000 su izdijeljene na blokove veličine 128x128 piksela, a baza je formirana izdvajanjem blokova i ručnim anotiranjem u šest klase i to prema sadržaju od interesa, pri čemu je ispred svakog naziva bloka dodan prefiks prema klasi kojoj se blok dodjeljuje. Ortofotografije su dijeljene na manje blokove kako bi se postigla veća homogenost obilježja na manjim blokovima nego što bi to bio slučaj kod cijelih slika. Tako se povećava vjerovatnoća da će se za semantički različite regone dobiti različiti deskriptori. Naime, podjela slika na regone je

fiksna, tako da je ona izdijeljena na regije pravilnog oblika – blokove veličine 128x128 piksela. Ovakva podjela ipak ne osigurava u potpunosti homogenost obilježja u blokovima, pa je moguće da deskriptori blokova sa nehomogenim obilježjima ne opisuju stvarni semantički sadržaj tih blokova. Odabранo je da bazu formiraju blokovi koji sadrže kuće, groblje, industrijsku zonu, njive, rijeku i zelenilo, pa će se tako i pretraživanje vršiti prema tim semantičkim sadržajima. Blok upit će, dakle, nakon klasifikacije u sistemu biti pridružen nekoj od sljedećih klasa: „Kuće“, „Groblje“, „Industrijska Zona“, „Njive“, „Rijeka“, „Zelenilo“. Na slici 5.1 prikazani su primjeri blokova za svaku od klasa.



Slika 5.1 – Primjeri klasa po kojima je vršena semantička segmentacija slike: (a)“Kuće“, (b)“Groblje“, (c)“Industrijska zona“, (d)“Njive“, (e)“Rijeka“, (f)“Zelenilo“

Šest klasa blokova razvrstanih prema samantičkom sadržaju čine dovoljno raznovrsnu bazu za vjernu evaluaciju uspješnosti klasifikacije. Kako se i u prirodi naše teksture od interesa pojavljuju na većoj ili manjoj površini, tako ni broj blokova po klasama nije ujednačen. Realno je očekivati neizbalansiranu bazu po kategorijama. Raspodjela broja slika iz baze po klasama je predstavljena dijagrameom na slici 5.2. Ukupno baza sadrži 606 blokova, anotiranih u 6 klasa.



Slika 5.2 - Raspodjela broja slika po klasama u bazi slika

Proces klasifikacije se može posmatrati kao proces iz dva koraka. U prvom koraku se određuju deskriptori teksture za svaki od blokova kako bi se numerički predstavila informacija koju nosi slika na konkretnom bloku. U drugom koraku se konkretni blok, na osnovu mjere sličnosti, pridružuje klasi kojoj se pridružuju blokovi sa sličnim osobinama.

Za reprezentaciju teksture blokova koriste se Gaborovi deskriptori opisani u odjeljku 3.3. Upotrebljeni Gaborovi filtri su raspoređeni na 5 skala i 6 orijentacija, sa donjom centralnom frekvencijom postavljenom na  $U_l = 0.05$ , a gornjom na  $U_h = 0.4$ . Implementiran Gaborov deskriptor teksture je invarijantan na rotaciju, što osigurava da će semantički slični blokovi, ali sa različitom dominantnom orijentacijom teksture u regionu, biti zaista označeni kao pripadnici iste klase. Kako bi se postigla invarijatnost deskriptora na rotaciju pronađena je dominantna orijentacija teksture kao orijentacija na kojoj je ukupna energija na svim skalama maksimalna. Deskriptor teksture se prema tome cirkularnim pomjeranjem modifikuje tako da komponente deskriptora na svakoj skali počinju dominantnom orijentacijom. Deskriptori teksture dobijeni primjenom Gaborove transformacije daju najbolje rezultate pri prepoznavanju semantike sadržaja blokova koji imaju pretežno homogenu strukturu tako da su se oni veoma dobro pokazali pri analizi i klasifikaciji blokova sa vazdušnih snimaka.

Eksperimentalno su spovedene tri metode klasifikacije deskriptora teksture u prostoru obilježja čiji su rezultati upoređivani i detaljnije obrazloženi. Za klasifikaciju su korišteni:

1. „Najbliži susjed“ (eng. Nearest-neighbour) klasifikacija
2. Samoorganizujuća Kohonenova mapa i klasifikacija na principu većinskog glasanja (eng. Majority Voting)
3. LVQ

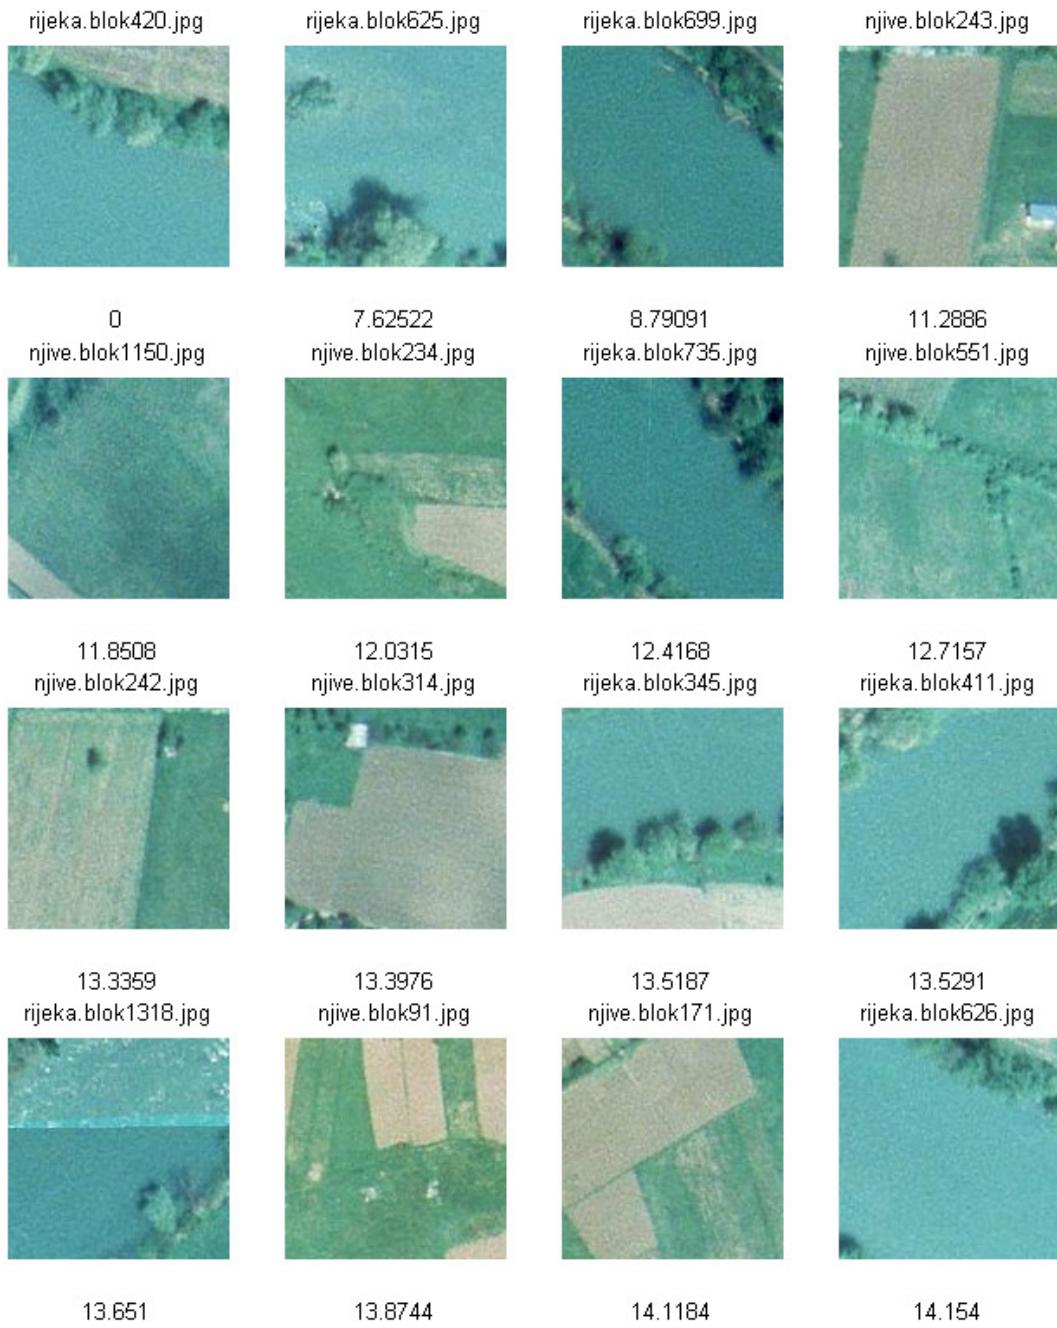
Rezultati testiranja za svaki od metoda klasifikacije slika upita su dati u poglavlju 5.2.

### 5.1.2 „Najbliži susjed“ klasifikacija

Pridruživanje klase upitu, bloku slike, se u ovom slučaju vrši na osnovu međusobnih udaljenosti vektora obilježja konkretnog bloka i ostalih blokova u bazi. Blokovi u bazi su prethodno anotirani pri čemu im je dodijeljena klasa. Anotacija se vršila na osnovu subjektivne vizuelne percepcije autora ovog rada i iako bi se izbor anotacija baze razlikovao za svakog od posmatrača ponaosob, ove razlike u globalnom pogledu ne bi imale velik uticaj na konačne performanse sistema sve dok su slične slike u istoj klasi. Slike su anotirane u šest klasa: „Kuće“, „Groblje“, „Industrijska zona“, „Njive“, „Rijeka“, „Zelenilo“ i taj isti skup će se koristiti u sva tri pristupa klasifikaciji ulaznih vektora upita. Na osnovu metrike opisane u poglavlju 3.2.2 određuju se međusobne udaljenosti, a posmatranom bloku se dodjeljuje klasa bloka čiji je vektor obilježja najmanje udaljen u prostoru obilježja od vektora posmatranog bloka. „Najbliži susjed“ klasifikacija je najjednostavniji primjer sistema za semantičku segmentaciju koji zahtijeva izračunavanje deskriptora teksture za blok upit, izračunavanje deskriptora teksture za svaki blok ponaosob iz baze i pretraživanje baze za najbližim deskriptorima blokova deskriptoru bloka upita, bez korištenja neuronskih mreža i klasterizacije blokova. Ovaj tip klasifikacije zahtijeva anotiranu bazu blokova kako bi se informacija o klasi pronađenog najsličnijeg bloka koja je sadržana u njegovoj anotaciji mogla dodijeliti bloku upitu.

Na slici 5.3 je dat primjer klasifikacije bloka upita koji se nalazi u gornjem lijevom uglu. Kao blok upit je upotrebljena slika koja se već nalazi u bazi i koja je anotirana kako bi se mogla validirati uspješnost klasifikacije. Udaljenosti deskriptora teksture blokova od deskriptora teksture bloka upita rastu idući slijeva na desno i odozgo

prema dole. Prema „Najbliži susjed“ principu klasifikacije bloku upitu je dodijeljena klasa Rijeka preslikana od njegovog najbližeg susjeda rijeka.blok625.jpg bloka. Poređenjem sa ručno dodijeljenom anotacijom bloka upita vidi se da je klasifikacija uspješno izvršena.



Slika 5.3 – Primjer „najbliži susjed“ klasifikacije. Upit je blok u gornjem lijevom uglu. Sličnost rezultata sa upitom opada idući sa lijeva na desno i odozgo prema dole. Iznad slika je naznačeno ime fajla koji su prethodno ručno anotirani. Ispod slika su udaljenosti od upita na osnovu jednačine (3.13) . Slike su veličine 128x128, a prikazano je samo najsličnijih 16 tekstura iz baze. Klasifikacijom je bloku upitu dodijeljena klasa „Rijeka“.

### 5.1.3 SOM mapa i klasifikacija na principu većinskog glasanja

Samoorganizujuća mapa (Odjeljak 4.4.2) na osnovu nenadgledanog učenja estimira distribuciju vektora u prostoru obilježja i u mogućnosti je da svaki novi upit (vektor obilježja) dodijeli odgovarajućem klasteru. Ova mreža transformiše 60-dimenzionalni prostor obilježja u dvodimenzionalnu diskretnu mapu pri čemu je očuvan topološki raspored vektora. Na ulazu mreže neuroni primaju 60-dimenzionalne deskriptore tekstura, dok 2D mapa na izlazu daje rezultate odluka o klasterizaciji ulaznih vektora. Ulaz i izlaz su potpuno povezani, a težine se uče u toku trening faze. SOM mapa je implementirana sa 100 izlaznih neurona slijedeći generalno pravilo da broj izlaznih nerona bude 10-15 puta veći od broja klasa.

Motivacija za korištenje ove mreže je što je ona u mogućnosti da adaptivno klasterizuje prostor obilježja i što su izlazni neuroni topološki raspoređeni tako da susjedni neuroni odgovaraju „sličnim“ klasterima u originalnom 60-dimenzionalnom prostoru. Prema tome, uz smanjenje dimenzije prostora sa kojim se barata ova mreža čuva topologiju prostora obilježja. Težine mreže se adaptiraju na osnovu kompetitivnog učenja. Svaki neuron u izlaznom sloju predstavlja jedinstven klaster ulaznih vektora obilježja blokova što znači da će za bilo koji ulazni vektor obilježja samo jedan neuron u izlaznom sloju biti aktiviran. Konačni rezultat je prostor obilježja izdijeljen po klasterima.

Faza treniranja se sprovodi dovodenjem vektora obilježja  $\mathbf{x}$  na ulaz mreže i korigovanjem težinskih vektora  $\mathbf{m}_i$  prema Kohonenovim pravilima za korekciju težina, jednačina (4.1). Na početku svi težinski vektori  $\mathbf{m}_i(0)$  se inicijalizuju na slučajne vrijednosti. Dalji proces ulazi u detaljnije razmatranje o SOM mapi što je prethodno objašnjeno.

Kako svaki neuron izlaznog sloja predstavlja klaster potrebno je grupisati i labelisati izlazne neurone, tj. dodijeliti im klase. Izlazni neuroni su pridruženi klasama na osnovu klasifikacije na principu većinskog glasanja. Po tom principu klasifikacije, neuronu će biti dodijeljena ona klasa koja odgovara najzastupljenijoj anotiranoj klasi ulaznih vektora na koje se aktivirao taj neuron. Radi demonstracije, na slici 5.4 prikazani su blokovi na koje se aktivirao jedan neuron. Ovaj klaster sadrži četiri bloka i na osnovu klasifikacije na principu većinskog glasanja, klasteru je pridružena klasa „Industrijska zona“. Dakle, klasifikacija je uspješna.



Slika 5.4 – Primjer uspješne klasifikacije klastera jednog neurona SOM mreže. Iznad slike je naznačeno ime fajla koji su prethodno ručno anotirani.

Primjer klastera proglašenog da pripada klasi „Njive“ dat je na slici 5.5. Pošto klaster sadrži tri bloka anotiranih kao klasa „Rijeka“, to bi moglo prouzrokovati neuspješnu klasifikaciju kad bi se na ulaz sistema dovela slika rijeka.blok699.jpg (ili slika slične teksture). Naime, ta slika anotirana kao klasa „Rijeka“ bi bila klasifikovana kao „Njive“.



Slika 5.5 – Primjer klasera jednog neurona SOM. Iznad slika je naznačeno ime fajla koji su prethodno ručno anotirani.

#### 5.1.4 LVQ

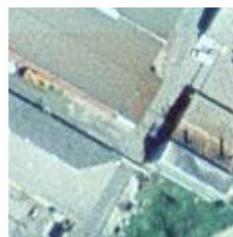
U odnosu na samoorganizujuću mapu, LVQ unosi dodatno fino podešavanje granica klastera kao što je objašnjeno u poglavlju 4.5. Prilikom projektovanja LVQ mreže vodilo se računa da skriveni sloj mreže ima 100 neurona isto kao SOM mapa kako bi se sistemi mogli upoređivati. Izlazni sloj ima 6 neurona prema broju klasa u sistemu, gdje je svaki neuron pridružen jednoj klasi. Klasifikacija ulaznog vektora je obavljena unutar same mreže, pa se uzima da je ulazni blok one klase kojoj pripada aktivirani neuron u izlaznom sloju. Na slici 5.6 prikazano je 16 blokova iz klase Industrijska zona kojoj je pridružen aktivirani neuron, a koji su sortirni po udaljenosti u rastućem poretku od bloka upita (prvi blok sa lijeve strane u prvom redu). Ukupan broj blokova koji su pridruženi

klasi Industrijska zona je 71, što je zadovoljavajući rezultat s obzirom da je u bazi ukupno 75 blokova anotiranih kao Industrijska zona (slika 5.2).

indZona.blok1043.jpg



indZona.blok1044.jpg



indZona.blok1007.jpg



indZona.blok1608.jpg



indZona.blok1042.jpg



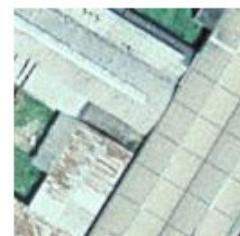
indZona.blok865.jpg



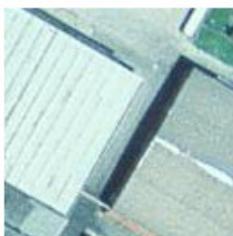
indZona.blok1607.jpg



indZona.blok1212.jpg



indZona.blok1008.jpg



indZona.blok992.jpg



indZona.blok921.jpg



indZona.blok1077.jpg



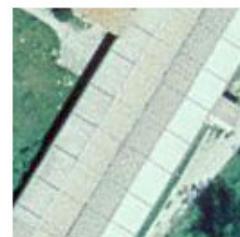
indZona.blok1009.jpg



indZona.blok754.jpg



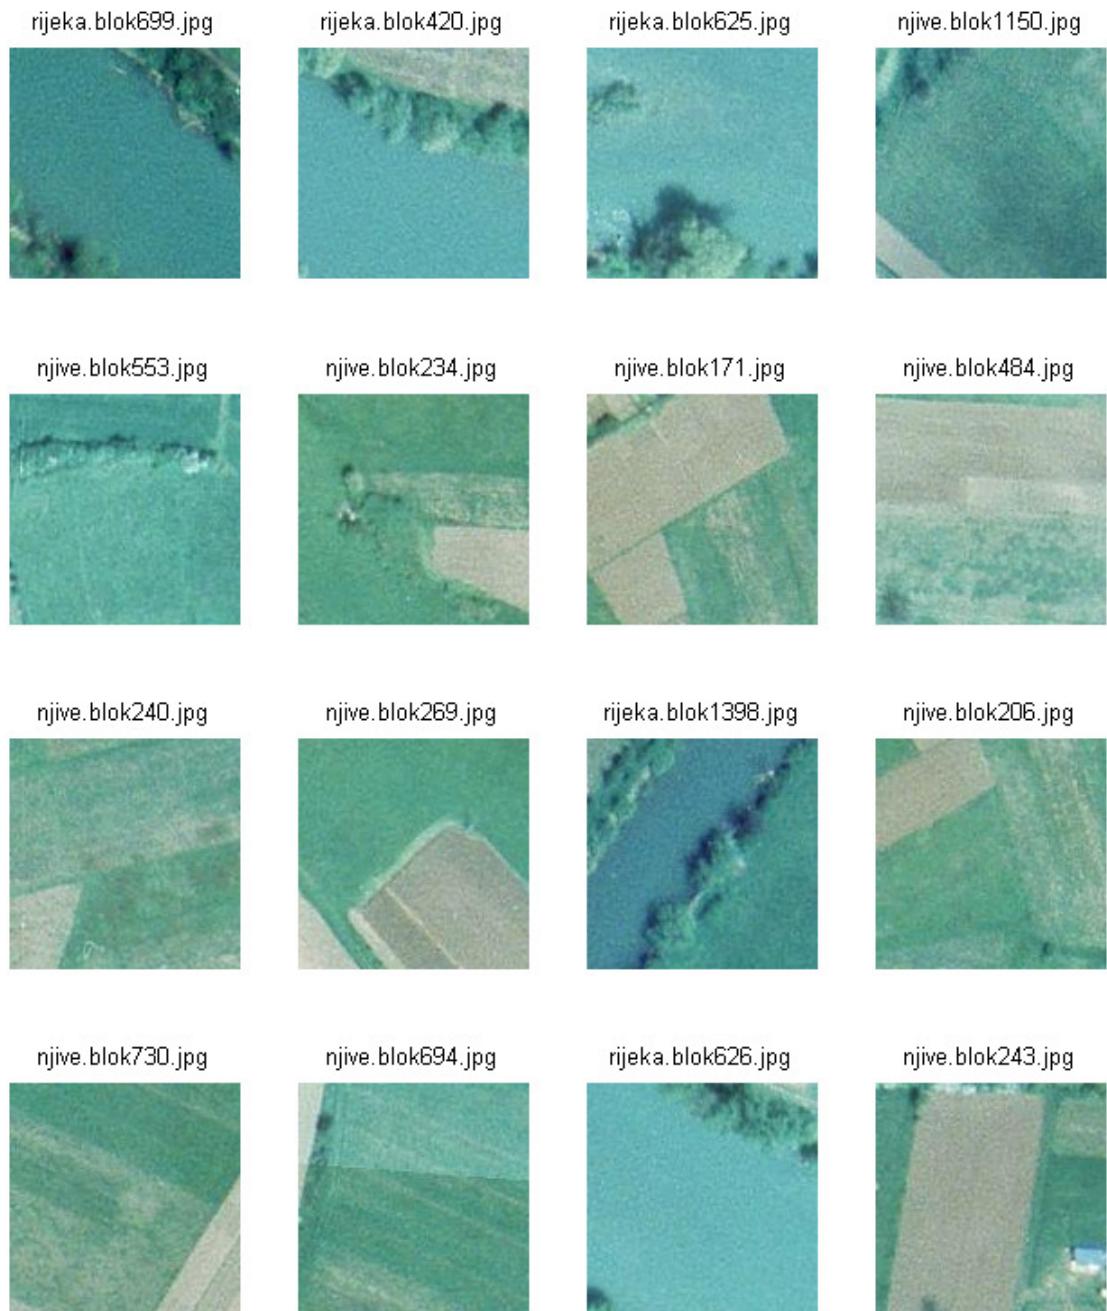
indZona.blok1178.jpg



indZona.blok887.jpg



Slika 5.6 – Primjer uspješne klasifikacije bloka upita – prvi blok sa lijeve strane u prvom redu anotiran kao Industrijska zona. Prikazano je najbližih 15 blokova od bloka upita dodijeljenih klasi Industrijska zona nakon LVQ mreže. Broj blokova pridruženih toj klasi je 71. Iznad slika je naznačeno ime fajla koji su prethodno ručno anotirani.



Slika 5.7 – Primjer neuspješne klasifikacije bloka upita – prvi blok sa lijeve strane u prvom redu anotiran kao Rijeka. Prikazano je najbližih 15 blokova od bloka upita dodijeljenih klasi Njive nakon LVQ mreže. Broj blokova pridruženih toj klasi je 238. Iznad slika je naznačeno ime fajla koji su prethodno ručno anotirani. Ispod slika su udaljenosti od upita na osnovu jednačine (3.13) .

Primjer neuspješne klasifikacije je dat na slici 5.7. Naime, prikazano je 16 blokova koji su sortirni po udaljenosti u rastućem poretku od bloka upita (prvi blok sa lijeve strane u prvom redu). Upit je klase Rijeka, ali je pridružen klasi Njive. Ukupan broj blokova koji su pridruženi klasi Njive je 238 što bi značilo da su klasi Njive izgleda pridruženi svi blokovi anotirani kao Njive i veći dio blokova anotiranih kao Rijeka. U bazi se nalazi 178 blokova klase Njiva i 77 blokova klase Rijeka (slika 5.2).

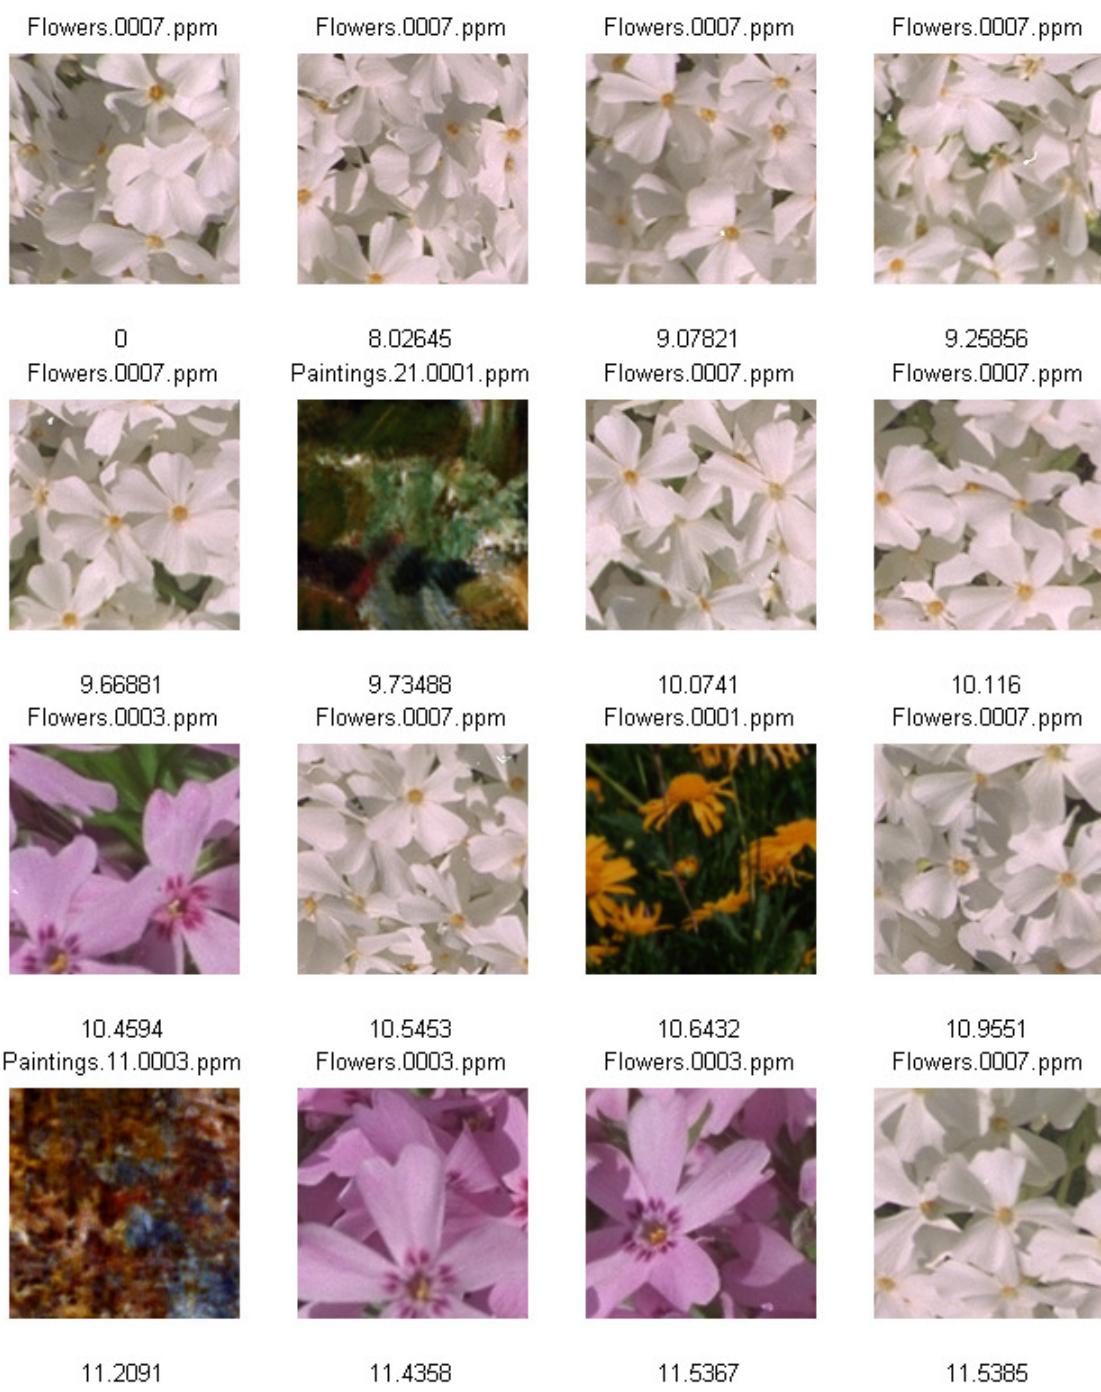
## 5.2 Testiranje sistema za semantičku segmentaciju

U ovom će odjeljku biti predstavljeni rezultati pretraživanja u Visual Texture bazi i bazi anotiranih blokova koje su obje opisane u 5.1.1. Tabelarno su prikazane statistike uspješnosti sistema realizovanih sa LVQ, SOM i „Najbliži susjed“ klasifikatorom, na osnovu kojih će se proračunavati tačnost klasifikacije sistema. Pred kraj poglavlja je dat demonstrativni primjer rada sistema za semantičku segmentaciju na konkretnoj ortofotografiji veličine 4500x6000 piksela.

Jedan primjer rezultata pretraživanja u Visual Texture na osnovu deskriptora teksture je već dat na slici 3.4. Rezultat pretraživanja je lista slika uređena prema opadajućoj sličnosti sa upitom. Pretraživanje se vrši sekvensijalno što ne bi bilo dovoljno efikasno rješenje u produkciji. Pažnja nije posvećena poboljšavanju efikasnosti pretraživanja jer je primarni cilj bio određivanje mjera sličnosti blokova, a ne brzina rada. Na slici 5.8 je dat rezultat pretraživanja u Visual Texture bazi pri čemu je upit dio slike sa Flowers.0007.ppm. Vektori obilježja tekstura pojedinih blokova veličina 128x128 piksela su upoređivani prema metričkoj koja se izračunava jednačinom (3.13). Na osnovu udaljenosti između deskriptora teksture blokova u odnosu na deskriptor tekture bloka upita donosili su se zaključci o sličnosti. Rezultati u određenoj mjeri odstupaju od očekivanog da svih 16 blokova u listi slika pripada slici Flowers.0007.ppm, no konzistentnost je održana u tome što pronađene najsličnije slike imaju isti semantički sadržaj kao upit - cvijeće.

Mogućnost sistema da pronalazi blokove slika u bazi koje su semantički slične upitu testirana je na kolekciji od 606 blokova anotiranih u 6 semantičkih kategorija. Ova baza blokova slika veličine 128x128 piksela dobijenih isjecanjem vazdušnih snimaka je opisana u 5.1.1.

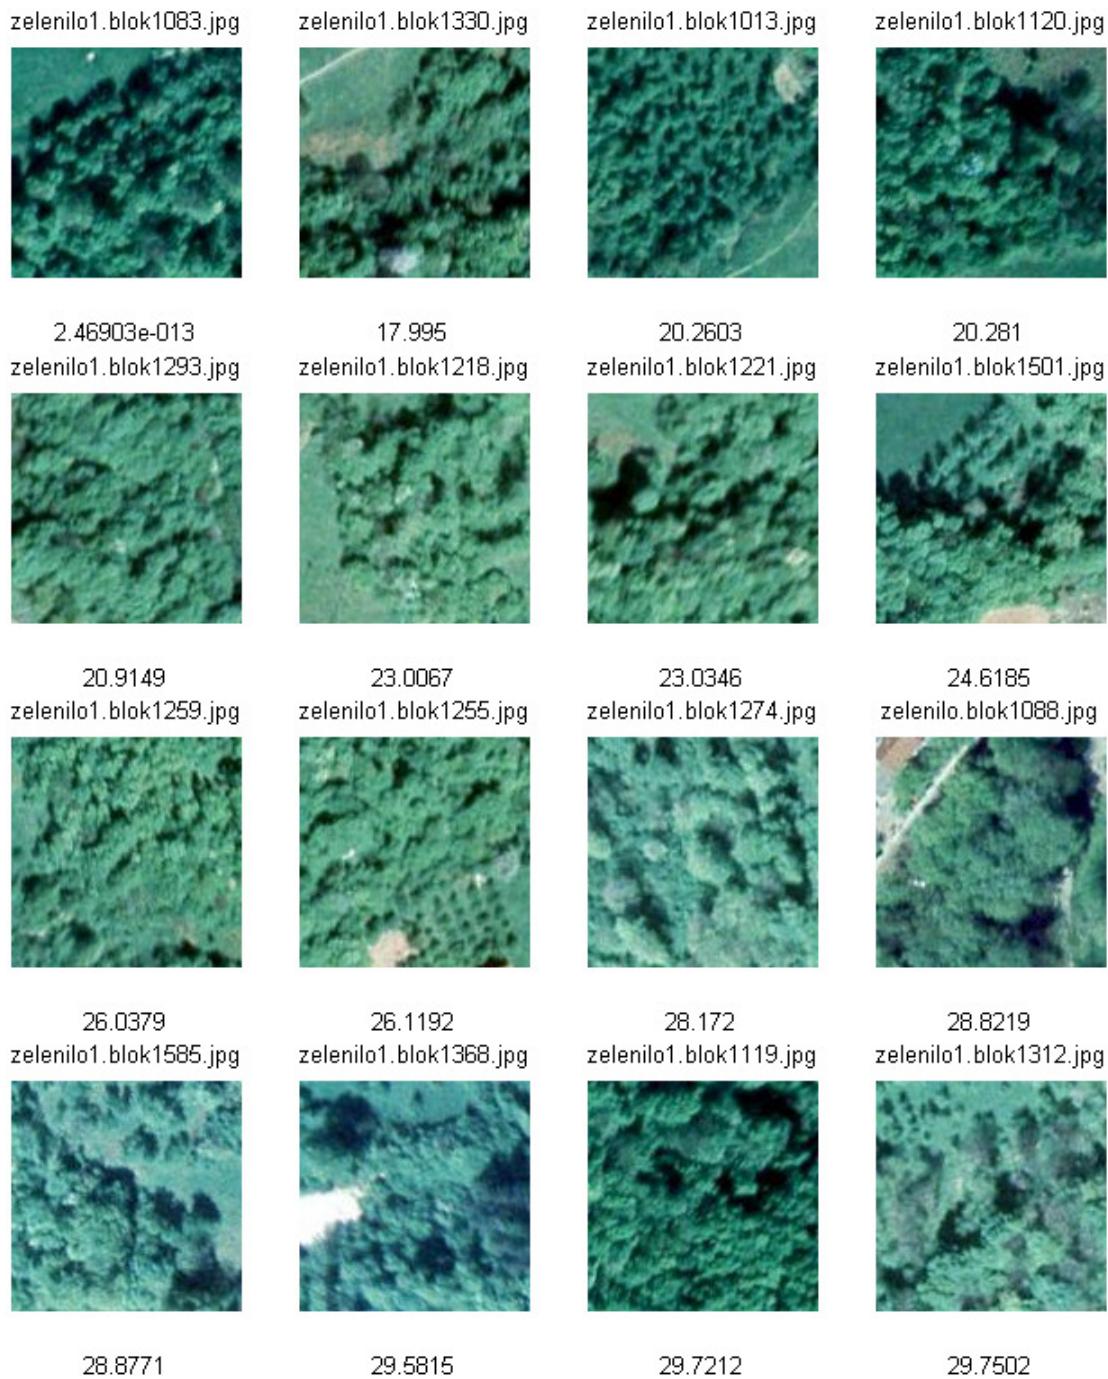
Primjeri rezultata pretraživanja za ovu bazu na osnovu deskriptora tekture su prikazani na slikama 5.9, 5.10 i 5.11. Na slici 5.9 je dat rezultat pretraživanja baze blokova na osnovu bloka upita iz klase „Kuće“. Pošto se testira sposobnost sistema da pronalazi i obilježi blokove koji su semantički slični upitu, bitnim se smatraju oni rezultati pretraživanja koji pripadaju istoj semantičkoj kategoriji kao i upit. Za svaki blok iz baze se određuje mjera sličnosti deskriptora tekture sa deskriptorom tekture blokom upita, a kao rezultat se prikazuju prvi 15 najbližih blokova pored bloka upita koji je u gornjem lijevom uglu. Sličnost opada idući slijeva na desno i odozgo prema dole. Slika 5.9 predstavlja odlične rezultate pretraživanja pošto prvi 16 pronađenih slika pripadaju istoj semantičkoj kategoriji kao i upit. Još jedan primjer pretrage baze blokova na osnovu bloka upita, a gdje su postignuti zadovoljavajući rezultati je prikazan na slici 5.10. Upit pripada klasi „Zelenilo“.



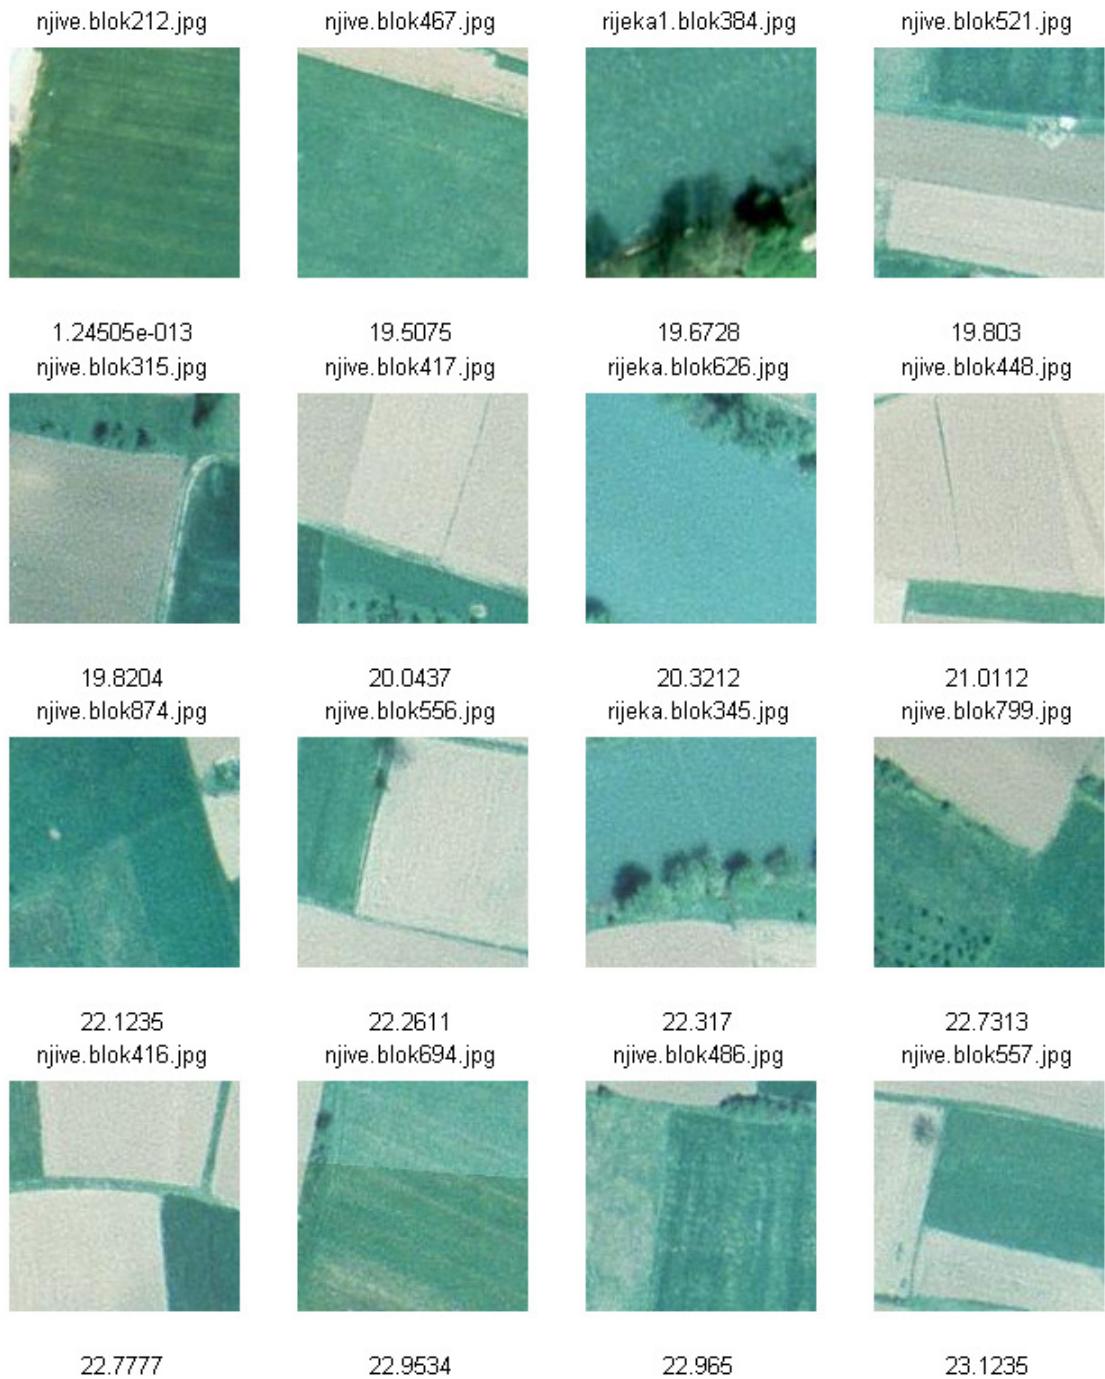
Slika 5.8 - Primjer pretraživanja Visual Texture baze slika na osnovu sličnosti teksura. Upit je slika u gornjem lijevom uglu. Sličnost rezultata sa upitom opada idući sa lijeva na desno i odozgo prema dole. Iznad slika je naznačeno ime fajla koji su prethodno ručno anotirani. Ispod slika su udaljenosti od upita na osnovu jednačine (3.13) . Slike su veličine 128x128, a prikazano je samo najsličnijih 16 tekstura iz baze.



Slika 5.9 - Primjer pretraživanja baze aero slika na osnovu sličnosti teksura. Upit je slika u gornjem lijevom uglu klase Kuće. Sličnost rezultata sa upitom opada idući sa lijeva na desno i odozgo prema dole. Iznad slika je naznačeno ime fajla koji su prethodno ručno anotirani. Ispod slika su udaljenosti od upita na osnovu jednačine (3.13) . Slike su veličine 128x128, a prikazano je samo najsličnijih 16 tekstura iz baze.



Slika 5.10 - Primjer pretraživanja baze aero slika na osnovu sličnosti teksura. Upit je slika u gornjem lijevom uglu klase Zelenilo. Sličnost rezultata sa upitom opada idući sa lijeva na desno i odozgo prema dole. Iznad slika je naznačeno ime fajla koji su prethodno ručno anotirani. Ispod slika su udaljenosti od upita na osnovu jednačine (3.13) . Slike su veličine 128x128, a prikazano je samo najsličnijih 16 tekstura iz baze.



Slika 5.11 - Primjer pretraživanja baze aero slika na osnovu sličnosti teksura. Upit je slika u gornjem lijevom ugлу klase Njive. Sličnost rezultata sa upitom opada idući sa lijeva na desno i odozgo prema dole. Iznad slika je naznačeno ime fajla koji su prethodno ručno anotirani. Ispod slika su udaljenosti od upita na osnovu jednačine (3.13) . Slike su veličine 128x128, a prikazano je samo najsličnijih 16 tekstura iz baze.

Ipak, pretraga samo na osnovu deskriptora tekture u nekim slučajevima nije dovoljna da bi se pronašli blokovi koji su zaista semantički slični. Naime, na slici 5.11 je dat primjer sa blokom upitom iz klase „Njive“ gdje su se čak u prvih 15 najsličnijih blokova našla tri bloka koja pripadaju klasi „Rijeka“. Ovo će se pokazati kao uzrok lošijih rezultata klasifikacije blokova koji bi trebali biti klasifikovani kao „Rijeka“, jer klasifikator neće biti u mogućnosti da prepozna da se na blokovima zaista nalazi rijeka. Ipak, bitno je uočiti da bi i ljudska procjena klasifikacije blokova na kojima se nalazi rijeka bila otežana zbog zaista velike sličnosti sa blokovima čiji semantički sadržaj predstavlja „Njivu“. Ovakva situacija zahtijeva dorađivanje deskriptora ekstrakcijom dodatnih vizuelnih obilježja pored obilježja tekture iz sadržaja blokova. Pomenuto poboljšavanje je ostavljeno za budući rad.

Fazi testiranja sistema za semantičku segmentaciju pristupa se razdvajanjem baze na dva skupa. Pošto su slike već anotirane automatski je omogućena adekvatna evaluacija rada sistema upoređivanjem klase koju je sistem dodijelio bloku upitu i klase koja je ručno dodijeljena anotiranjem bloka. Veći skup se koristi za treniranje neuronske mreže i što su blokovi unutar iste klase raznovrsniji i brojniji to će sistem biti više u mogućnosti da pravilno klasificuje blok upit. Iz manjeg skupa se uzimaju blokovi koji se dovode na ulaz sistema i čija klasifikacija se traži.

Baza je razdvojena na 90% blokova koji su korišteni za treniranje neuronske mreže, a preostalih 10% blokova su testni blokovi. Sistemu za klasifikaciju se na ulaz dovodi po jedan blok iz testnog skupa. Kako se sistem za klasifikaciju blokova zasniva na reprezentaciji blokova pomoću deskriptora tekture za svaki od blokova je izračunat Gaborov vektor obilježja. Ti 60-dimenzionalni vektori obilježja se dovode na ulaz u neuronsku mrežu. Podrazumijeva se da je u tom trenutku neuronska mreža već istrenirana i naučena.

U svrhu dobijanja statističkih podataka o ponašanju sistema, postupak treniranja i testiranja SOM i LVQ neuronskih mreža vršen je deset puta uzastopno svaki put sa slučajno odabranim trening (90%) i testnim skupom (10%). Za svaki ulazni blok iz testnog skupa traži se klasifikacija, pri čemu se pod tačnom klasom bloka podrazumijeva dodijeljena klasa ručnim anotiranjem, a procijenjena klasa je klasa dobijena na izlazu sistema. Relevantnim se smatraju svi rezultati klasifikacije bez obzira da li je klasifikacija ispravna, pošto se traže procenti i tačnih i netačnih odgovora. Procenat tačnih odgovora za određenu klasu se dobije dijeljenjem broja blokova proglašenih kao ispravno klasifikovani, sa ukupnim brojem blokova te klase u testnom skupu. Procenti netačnih odgovora za određenu klasu se izračunavaju za svaku od preostalih klasa ponaosob, dijeljenjem broja netačno klasifikovanih blokova po svakoj preostaloj klasi sa ukupnim brojem blokova u testnom skupu koji pripadaju klasi za koju se traži statistika. Na primjer, za izračunavanje procenta tačnih odgovora za klasu „Kuće“ iz testnog skupa blokova, na ulaz sistema se dovode svi blokovi anotirani kao klasa „Kuće“. Sistem daje procijenjene klase, a prebrojavanje broja blokova sa procijenjenom klasom „Kuće“ i dijeljenjem sa ukupnim brojem blokova iz testnog skupa anotiranih kao „Kuće“ daje procenat tačnih odgovora. Dalje, prebrojavanjem broja blokova sa procijenjenom klasom, na primjer, „Njive“ i dijeljenjem sa ukupnim brojem blokova iz testnog skupa anotiranih kao „Kuće“ daje procenat koliko se dobilo odgovora klase „Njive“ kad su na ulazu dovođeni svi blokovi klase „Kuće“ iz testnog skupa. Isti postupak određivanja procenata netačnih odgovora ponavlja se i za preostale klase.

Testirano je ponašanje sistema u tri načina implementacije: sistem sa LVQ hibridnom mrežom, sistem sa neuronском mrežом tipa SOM uz klasifikaciju po principu većinskog glasanja i sistem sa klasifikacijom „Najbliži susjed“. Implementacija sistema sa LVQ mrežom je detaljnije opisana u 5.1.4. U jednoj iteraciji se slučajnim odabirom bira 90% blokova iz baze za trening skup, a preostali dio blokova za test skup. Nakon treniranja mreže, blokovi iz testnog skupa se dovode na ulaz. Tad se izračunavaju procenti tačnih i netačnih odgovora za svaku klasu ponaosob i formira se tzv. matrica konfuzije. Matrica konfuzije prikazuje procenat tačne i netačne klasifikacije. Redovi matrice predstavljaju stvarne (tačne) klase, a kolone su procijenjene klase na izlazu sistema. Prema broju klasa na koje se vrši klasifikacija u realizovanom sistemu, matrica konfuzije ima šest redova i šest kolona. Procenti tačne i netačne klasifikacije u matrici konfuzije su prikazani kao vrijednosti iz skupa [0,1], pri čemu 0 govori da nijedan blok iz testnog skupa nije pripao posmatranoj klasi, a 1 da su svi blokovi iz testnog skupa pripali posmatranoj klasi. Postupak odabira trening i testnih skupova, te izračunavanje matrica konfuzije se izvodi deset puta, nakon čega se traži srednja vrijednost matrica konfuzije za posmatranih deset iteracija. Za sve tri realizacije sistema usrednjena matrica konfuzije se proračunava na isti način, pri čemu se vodilo računa da se statistike sistema u sve tri realizacije izračunavaju na istim trening/testnim skupovima kako bi njihovo poređenje dovelo do validnih zaključaka.

Usrednjene matrice konfuzije za sva tri oblika realizacije su date u Tabeli 5.1. Upravo te matrice konfuzije predstavljaju mjere kvaliteta klasifikacije. Ukoliko sistem dobro radi, matrica konfuzije bi trebala biti strogo dijagonalno dominantna matrica (eng. strictly diagonally dominant matrix), tj. matrica kod koje je apsolutna vrijednost svake vrijednosti na dijagonali veća od sume apsolutnih vrijednosti svih ostalih vrijednosti u tom redu.

Tabela 5.1 – Rezultujće matrice konfuzije za neizbalansiran skup slika

- (a) Usrednjena matrica konfuzije za sistem sa LVQ hibridnom mrežom,
- (b) Usrednjena matrica konfuzije za sistem sa neuronском mrežом tipa SOM i većinskim glasanjem kao tehnikom klasifikacije
- (c) Usrednjena matrica konfuzije za sistem sa klasifikacijom „Najbliži susjed“ tehnikom

(a)

		Procijenjena klasa					
Tačna klasa		Kuće	Groblje	Industrijska zona	Njive	Rijeka	Zelenilo
	<b>Kuće</b>	<b>0.9137</b>	0.0144	0.0432	0	0	0.0288
	<b>Groblje</b>	0.1667	<b>0.7333</b>	0.0333	0.0667	0	0
	<b>Industrijska zona</b>	0.1954	0	<b>0.6207</b>	0.1149	0.0115	0.0575
	<b>Njive</b>	0	0	0.0115	<b>0.9770</b>	0	0.0115
	<b>Rijeka</b>	0.0164	0	0.1311	0.7213	<b>0.0328</b>	0.0984
	<b>Zelenilo</b>	0.3866	0.0168	0.0084	0.0168	0	<b>0.5714</b>

(b)

	Procijenjena klasa						
Tačna klasa		Kuće	Groblje	Industrijska zona	Njive	Rijeka	Zelenilo
	<b>Kuće</b>	<b>0.8489</b>	0.0288	0.0360	0	0	0.0863
	<b>Groblje</b>	0.3333	<b>0.5000</b>	0	0.0667	0.0333	0.0667
	<b>Industrijska zona</b>	0.1724	0.0115	<b>0.6552</b>	0.1034	0.0345	0.0230
	<b>Njive</b>	0.0057	0.0057	0.0287	<b>0.8736</b>	0.0862	0
	<b>Rijeka</b>	0	0	0.0984	0.5246	<b>0.3115</b>	0.0656
	<b>Zelenilo</b>	0.3529	0.0084	0.0252	0.0168	0.0420	<b>0.5546</b>

(c)

	Procijenjena klasa						
Tačna klasa		Kuće	Groblje	Industrijska zona	Njive	Rijeka	Zelenilo
	<b>Kuće</b>	<b>0.9424</b>	0.0144	0.0144	0	0	0.0288
	<b>Groblje</b>	0.2000	<b>0.7333</b>	0	0	0	0.0667
	<b>Industrijska zona</b>	0.1264	0	<b>0.8046</b>	0.0345	0.0345	0
	<b>Njive</b>	0	0	0	<b>0.8161</b>	0.1782	0.0057
	<b>Rijeka</b>	0.0164	0	0	0.2951	<b>0.5738</b>	0.1148
	<b>Zelenilo</b>	0.0672	0	0	0	0.0672	<b>0.8655</b>

U Tabeli 5.1(a) posmatrajući vrijednosti na dijagonali matrice konfuzije sistema za LVQ klasifikator, vidi se da sistem daje veoma dobre rezultate za klase „Kuće“, „Groblje“, „Industrijska Zona“, „Njive“ i „Rijeka“. Dakle, u 94,24% slučajeva su blokovi anotirani kao „Kuće“ zaista i prepoznati kao klasa „Kuće“. Za klasu „Rijeka“ vidi se da je 72,13% blokova na ulazu sistema sa sadržajem rijeka klasifikovano kao klasa „Njive“, zbog zaista velike sličnosti tekstura blokova čiji su semantički sadržaji njive i rijeka. Prema slici 5.2 koja pokazuje raspodjelu broja blokova u bazi po klasama, broj blokova klase „Njiva“ je mnogo veći od broja blokova klase „Rijeka“ zbog čega se i desilo da su većina blokova „Rijeka“ klasifikovani kao „Njive“, a ne obrnuto. Kao mjera kvaliteta klasifikacije računa se tačnost procjene pomoću matrice konfuzije. Tačnost procjene predstavlja procenat ukupnog broja tačnih odgovora u sistemu, a računa se kao količnik zbir elemenata na dijagonali i zbir svih elemenata u matrici. Za sistem sa LVQ klasifikatorom tačnost iznosi 64,15%.

Tabela 5.2(b) predstavlja matricu konfuzije sistema sa SOM klasifikatorom. Rezultati za klase kod kojih je LVQ dao veoma dobre rezultate: „Kuće“, „Groblje“, „Industrijska zona“, „Njive“ i „Rijeka“ su nešto slabiji kod SOM klasifikatora iz razloga što LVQ nakon klasifikacije unosi dodatno fino podešavanje granica klastera. Ipak gledajući globalnu sliku uspješnosti ovog tipa sistema, SOM ne zaostaje puno za LVQ klasifikatorom. To se potvrđuje i iz tačnosti procjene koja za LVQ klasifikator iznosi 62,4%, a ona upravo govori o procentu tačnih odgovora generalno u sistemu.

Izračunata je i matrica konfuzije za „Najbliži susjed“ klasifikator predstavljena u Tabeli 5.1(c). Interesantno je primjetiti da je ovaj klasifikator ostvario dosta dobre rezultate jednostavnom dodjelom klase upitu na osnovu klase bloka sa „najbližim“ deskriptorom, a ne uopštavajući pretraživanje pomoću neuronskih mreža. Dobri rezultati „Najbliži susjed“ klasifikatora se ogledaju u tačnosti procjene koja iznosi 78,93%. Ovim neuronske mreže nisu potisnute iz razloga što omogućavaju dosta brži rad sistema, što je naročito primjetno u velikim bazama slika. Naime, „Najbliži susjed“ klasifikator pri procjeni klase bloka upita mora izračunavati deskriptore teksture za svaki blok iz testnog skupa, dok je neuronska mreža naučila relacije između blokova različitih klasa i izračunavanjem deskriptora teksture samo bloka upita i njegovom pozicijom u prostoru obilježja daje odgovor kojoj klesi blok upit pripada. Pored toga, još bitnije je da će neuronske mreže dati daleko bolje rezultate kad se istreniraju sa mnogo većim brojem blokova jer će tad imati više materijala za učenje i kvalitetniju klasifikaciju. S tako istreniranom mrežom, čak i u slučajevima kad su slike unutar iste klase dosta različite, neuronske mreže će dati vjerniju klasifikaciju od jednostavnog „Najbliži susjed“ klasifikatora.

Potrebno je još dati detaljnije obrazloženje razloga klasifikacije blokova sa sadržajem „Rijeka“ kao klasa „Njive“. Slika 5.7 je dobar primjer za ovaj slučaj gdje je upit klase „Rijeka“ klasifikovan kao klasa „Njive“. Naime, dobijene matrice konfuzije za sisteme sa SOM i LVQ klasifikatorom pokazuju nemogućnost pravilne klasifikacije kad je u pitanju klasifikacija slika klase „Rijeka“ koja je slična klesi „Njive“. Manji broj trening primjera klase „Rijeka“ u odnosu na broj primjera klase „Njive“, izgleda nije dovoljan da se formira reprezentacija (procijeni funkcija gustine raspodjele) i „Njive“ imaju prednost u fazi klasifikacije. Tu se pokazuje loša strana metoda obučavanja, jer „Najbliži susjed“ klasifikator, koji je neparametarski i ne pravi nikakvu internu reprezentaciju, radi znatno bolje. Klasa blokova „Groblje“ je očito dovoljno različita od ostalih klasa (tj. vektori obilježja su dovoljno daleko) da mali broj trening primjera nije problem.

U toku daljeg testiranja uočeno je da se performanse sistema poboljšavaju dodavanjem novih trening primjera tj. težnjom ka izbalansiranom skupu po kategorijama. Do zaključka se došlo testiranjem sistema sa izbalansiranim skupom, po 31 blokova za svaku kategoriju pri čemu je kategorija „Groblje“ u ovom slučaju izostavljena zbog jako malog broja sličica te kategorije. Pokazni rezultat trening/testiranja sistema za izbalansiran skup sa LVQ hibridnom mrežom je sumiran u slijedećoj matrici konfuzije.

Tabela 5.2 – Matrica konfuzije za izbalansiran skup sa LVQ mrežom

	Procijenjena klasa					
	Kuće	Industrijska zona	Njive	Rijeka	Zelenilo	
Tačna klasa	Kuće	0.8438	0	0	0	0.1563
	Industrijska zona	0	0.6667	0.1515	0.0909	0.0909
	Njive	0	0.0333	0.7333	0.2000	0.0333
	Rijeka	0	0.0833	0.5833	0.2083	0.1250
	Zelenilo	0.1290	0.0323	0.0323	0.0323	0.7742

Ujednačenjem broja slika po klasama (balansiranjem), performanse za klasu "Rijeka" se svode na nivo slučajnog (1/5 za slučaj sa 5 klasa). Klasifikator se u ovom slučaju uspio pravilno realizovati, ali zbog sličnosti sa klasom "Njive" klasifikator nije u mogućnosti da dodijeli upitnoj slici klase "Rijeka" tu istu klasu, pa je rezultat na nivou slučajne procjene za ovu klasu. Za klasu "Njive" performanse su mnogo bolje jer klasifikator ima "materijala" za pravilnu klasifikaciju zbog blokova te klase dosta različitog sadržaja. Ipak, bitno je napomenuti da je realnije očekivati neizbalansiran skup na ulazu sistema u odnosu na izbalansiran.

Nameće se zaključak da bi uspješnost sistema bila poboljšana treniranjem mreže na većem, izbalansiranim skupu, a nakon toga testiranjem na realnom skupu slika za koje nas interesuje klasifikacija.

Sistem je tako projektovan da može izdijeliti proizvoljno velik vazdušni snimak na ulazu na blokove veličine 128x128 piksela, te da za svaki od tih blokova izračuna deskriptor teksture. Deskriptori teksture se zatim vode na ulaz neuronske mreže. Radi demonstracije rada sistema, ortofotografija sa slike 5.12 će biti dovedena na ulaz sistema sa SOM, LVQ i „Najbliži susjed“ klasifikatorom ponaosob. Konkretna ulazna slika je izdijeljena na 1610 blokova i nije potpuno nepoznata sistemu, jer je nekoliko blokova sa ove slike iskorišteno za formiranje baze anotiranih blokova za učenje neuronske mreže. Ta baza je predstavljena u 5.1.1 i sadrži 606 blokova raspoređenih po klasama kao na Slici 5.2. Na slikama 5.13, 5.14, 5.15 su date klasifikovane slike sa izlaza sistema sa SOM, LVQ i „Najbliži susjed“ klasifikatorom, respektivno. Radi uvjerljivije demonstracije, dobijenim klasifikovanim slikama je procenat neprovidnosti (eng. opacity) postavljen na 40% i kao takve su kopirane na originalnu ortofotografiju sa slike 5.12. Neizmjenjene klasifikovane slike sa izlaza sistema su priložene na CD-u.

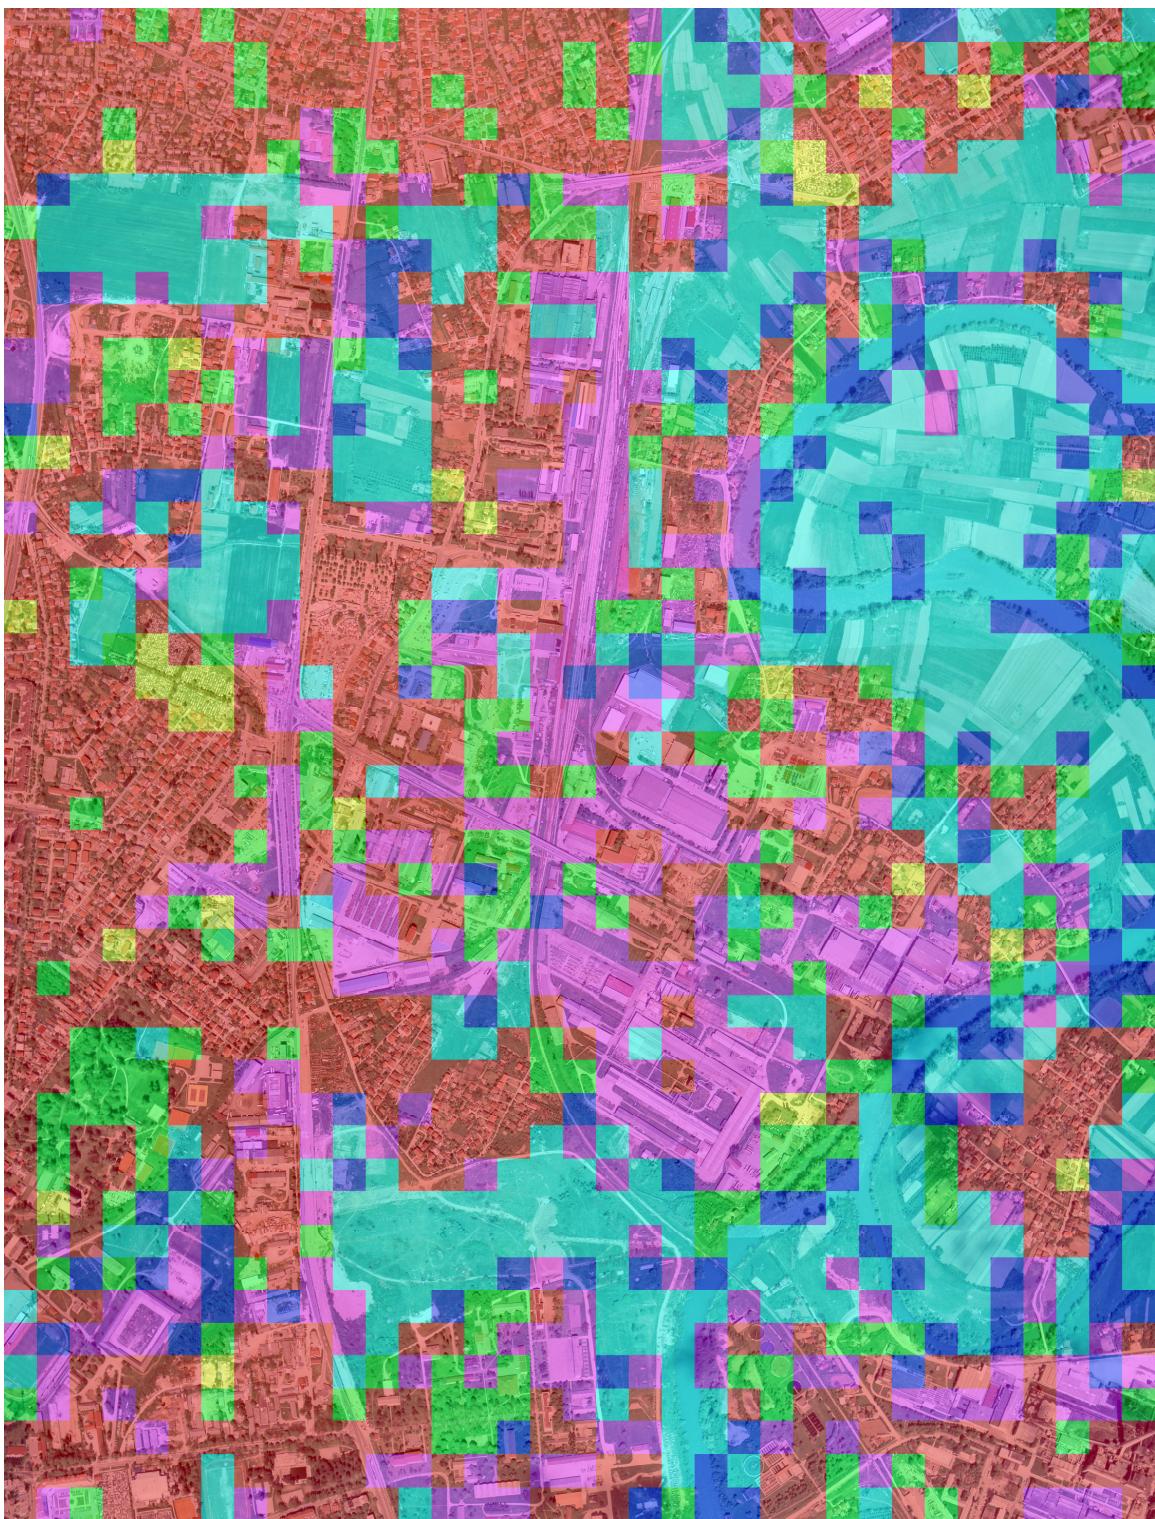
Sistemi sa SOM i LVQ klasifikatorom, koriste mreže koje su već istrenirane blokovima iz baze sa 606 anotiranih blokova. Na osnovu naučene topologije vektora obilježja blokova iz baze u prostoru obilježja, neuronske mreže lako rasporede u tom prostoru i vektore blokova sa nepoznate slike. LVQ i SOM dodjeljuju klasu bloku ulazne slike na osnovu klase klastera kojem je pridružen vektor obilježja tog bloka. Sistem sa

„Najbliži susjed“ klasifikatorom koristi istu bazu kako bi pronašao blok čiji je deskriptor teksture najbliži bloku upitu sa slike na ulazu. Tako se bloku upitu dodjeljuje klasa bloka sa najbližim deskriptorom.

Trenutna implementacija sistema obezbjeđuje klasifikaciju u šest kategorija: „Kuće“, „Groblje“, „Industrijska zona“, „Njive“, „Rijeka“ i „Zelenilo“. Na slikama 5.13, 5.14 i 5.15 blokovi klasifikovani kao „Kuće“ su predstavljeni crvenom bojom, „Groblje“ žutom, „Industrijska zona“ ljubičastom, „Njive“ tirkiznom (eng. cyan), „Rijeka“ plavom i „Zelenilo“ zelenom. Svi blokovi čiji semantički sadržaj vizuelno ne pripada ni jednoj od navedenih klasa biće pridruženi klasi kojoj je deskriptor teksture tog bloka najbliži u prostoru obilježja. Klasifikatori daju veliku tačnost kad je sadržaj bloka uniforman po pitanju semantičke klase.



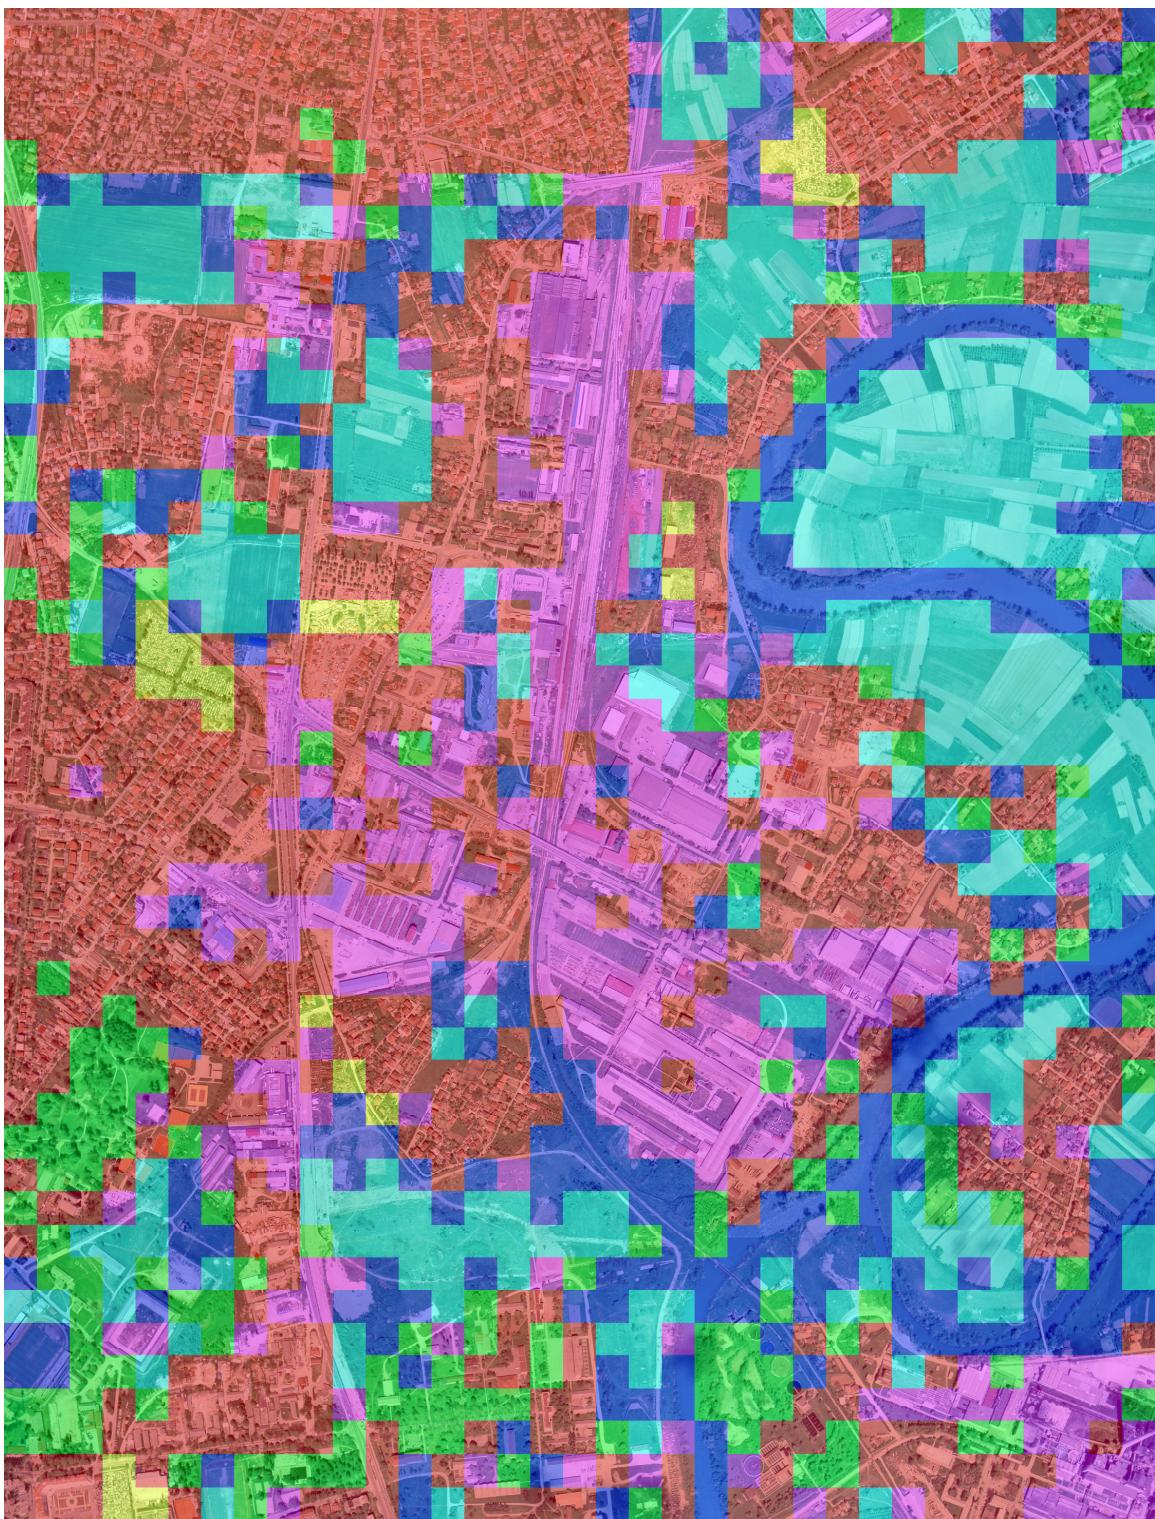
Slika 5.12 – Ortofotografija regije Banja Luke, u originalnoj veličini je omjera 1:5000 i veličine 4500x6000 piksela. Ovdje je umanjena.



Slika 5.13 – Klasifikovana ortofotografija sa slike 5.12 uz pomoć SOM klasifikatora. Klasifikovani blokovi na izlazu sistema su veličine 128x128 piksela, ali su za prikaz u radu proporcionalno umanjeni. Blokovi klasifikovani kao „Kuće“ su predstavljeni crvenom bojom, „Groblje“ žutom, „Industrijska zona“ ljubičastom, „Njive“ tirkiznom (eng. cyan), „Rijeka“ plavom i „Zelenilo“ zelenom.



Slika 5.14 – Klasifikovana ortofotografija sa slike 5.12 uz pomoć LVQ klasifikatora. Klasifikovani blokovi na izlazu sistema su veličine 128x128 piksela, ali su za prikaz u radu proporcionalno umanjeni. Blokovi klasifikovani kao „Kuće“ su predstavljeni crvenom bojom, „Groblje“ žutom, „Industrijska zona“ ljubičastom, „Njive“ tirkiznom (eng. cyan), „Rijeka“ plavom i „Zelenilo“ zelenom.



Slika 5.15 – Klasifikovana ortofotografija sa slike 5.12 sa „Najbliži susjed“ klasifikatorom. Klasifikovani blokovi na izlazu sistema su veličine 128x128 piksela, ali su za prikaz u radu proporcionalno umanjeni. Blokovi klasifikovani kao „Kuće“ su predstavljeni crvenom bojom, „Groblje“ žutom, „Industrijska zona“ ljubičastom, „Njive“ tirkiznom (eng. cyan), „Rijeka“ plavom i „Zelenilo“ zelenom.

## 6. ZAKLJUČAK

Internacionalni interes za daljinsko snimanje sve više raste kako u vojnom tako i javnom sektoru. Podaci iz senzora za daljinsko snimanje dolaze u različitim formama. Ipak, slike dominiraju arhivama podataka dobijenih daljinskim snimanjem kako po broju tako i po vrstama. Primjene daljinskog snimanja u civilnom sektoru su brojne: prognoza vremena, dugoročne studije o klimi, praćenje atmosferskog ozona, predviđanje roda usjeva, i pomaganje farmerima u određivanju poljoprivredne kulture itd.

Razvijeni su brojni algoritmi pronalaženja i prepoznavanja obilježja na vazdušnim i satelitskim slikama dobijenih daljinskim snimanjem, a jedan od pristupa rješenju je opisan u ovom radu. U eksperimentalnom dijelu su prikazani rezultati dobijeni na vazdušnim snimkama, a isti pristup se može koristiti i na satelitskim. Rješenje se bazira na pronalaženju Gaborovog deskriptora teksture za svaki od blokova izdijeljene slike čiji sadržaj se analizira. Određivanje sličnosti između deskriptora je vršeno na osnovu metrike Minkovskog za  $p=1$  prema jednačini (3.13) pa je „sličnim“ blokovima sa sličnom raspodjelom vizuelnog obilježja tekture dodijeljena ista klasa. Ovim postupkom se na izlazu sistema dobija klasifikovana slika po blokovima veličine 128x128 piksela.

Ispitivani su SOM, LVQ i „Najbliži susjed“ klasifikatori koji su ostvarili zadovoljavajuću tačnost klasifikacije, čak i sa relativno malim brojem anotiranih blokova za treniranje neuronskih mreža iz baze opisane u 5.1.1 sa 606 blokova. Za poboljšavanje rezultata, a bez dodatne implementacije u sistemu, potrebno je jednostavno proširiti postojeću bazu novim anotiranim blokovima, te postupak treniranja ponoviti.

Za budući rad je ostavljeno da se klasifikatori poboljšaju uvođenjem segmentacije na regije pred postupak nalaženja deskriptora tih regija. Naime, ovim postupkom bi bilo izbjegnuto „zbunjivanje“ deskriptora kad se na istom bloku nađe više obilježja (npr. zelenilo i kuće uz rijeku). Ovdje će se morati voditi računa o dopunjavanju regija dobijenih segmentacijom do pravougaonih kako bi se mogli direktno izračunati deskriptori teksture. U radu [5] je pokazano da je bolje dopunjavati regije njihovim slikama u ogledalu u odnosu na dopunjavanje regona nulama, kako bi se izbjeglo unošenje nepostojećeg frekventnog sadržaja. Pored segmentacije, u nekoliko navrata se došlo do zaključka da bi uvođenje deskriptora boje pored deskriptora tekture moglo da poboljša rezultate i pomogne klasifikatoru u vjernijoj klasifikaciji prema procjeni posmatrača. Ipak, eventualni problemi i prevazilaženje istih dodatnim poboljšanjima zahtjeva nova eksperimentalna istraživanja za koja svakako da ima motivacije iz razloga sve veće popularnosti oblasti daljinskog snimanja.

## 7. LITERATURA

- [1] Program GLOBE – daljinsko snimanje,  
<http://public.carnet.hr/globe/prirucnik/daljinsko%20istrazivanje.PDF>, zadnji put posjećeno 15.4.2009.
- [2] H.K. Ramapriyan, *Image Databases: Search and Retrieval of Digital Imagery*, str.35-82, John Wiley&Sons, 2002
- [3] Zdenka Babić, *Digitalna obrada slike, skripta*, Banja Luka, 2005.
- [4] W. K. Pratt, *Digital Image Processing: PIKS Inside, Third Edition*, John Wiley & Sons, Inc, 2001
- [5] Vladimir Risojević, *Pretraživanje baza slika na osnovu sličnosti regionala*, magistarska teza, Banja Luka, 2006.
- [6] R. C. Gonzales, R. E. Woods, *Digital Image Processing – Second Edition*, Prentice Hall, Inc., New Jersey, 2002.
- [7] B.S. Manjunath, W.Y. Ma, *Texture Features for Browsing and Retrieval of Image Data*, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 18, No. 8, August 1996
- [8] Wei-Ying Ma, B. S. Manjunath, „Texture features and learning similarity,“ *Proceedings of IEEE International Conference on Computer Vision and Patter Recognition*, str. 425-430, 1996
- [9] D. Gabor, *Theory of communication*, In J. IEE, vol. 93, str. 429-457, London, 1946.
- [10] Wei-Ying Ma, B. S. Manjunath, „A texture Thesaurus for Browsing Large Aerial Photographs,“ *Journal of American Society for Information Science*, br. 49(7), str. 633-648, 1998.
- [11] Dengsheng Zhang, Guojun Lu, *Content-based image retrieval using Gabor texture features*, In Proc. of First IEEE Pacific-Rim Conference on Multimedia (PCM ‘00), str. 329-395, Sydney, Australia, 2000
- [12] Edukacijski repozitorij za Inteligentne sustave, <http://eris.foi.hr/11neuronske/nnpredavanje1.html>, zadnji put posjećeno 1.04.2009.
- [13] K. Gurney, *An Introduction to Neural Networks*, UCL Press, 1997
- [14] V. Lojanica, diplomski rad, *Uloga veštačkih neuronskih mreža u predviđanju*, Fakultet organizacionih nauka, Beograd, 2001

- [15] L. Fausett, *Fundamentals of Neural Networks: Architectures, Algorithms and Application*, Prentice Hall, 1994.
- [16] R.O. Duda, P.E. Hart, D.G. Stork, *Pattern Classification – Second Edition*, Wiley-Interscience, 2000
- [17] H. Demuth, M. Beale, *Neural Network Toolbox User's Guide*, The MathWorks, Inc., 2002
- [18] P. Somervuo, T. Kohonen, *Self-Organizing Maps and Learning Vector Quantization for Feature Sequences*, Helsinki University of Technology, Neural Networks Research Centre, Finland, 2004
- [19] Vision Texture Database, MIT,  
<http://vismod.media.mit.edu/vismod/imagery/VisionTexture/vistex.html>, zadnji put posjećeno 29.03.2009.

## 8. DODATAK

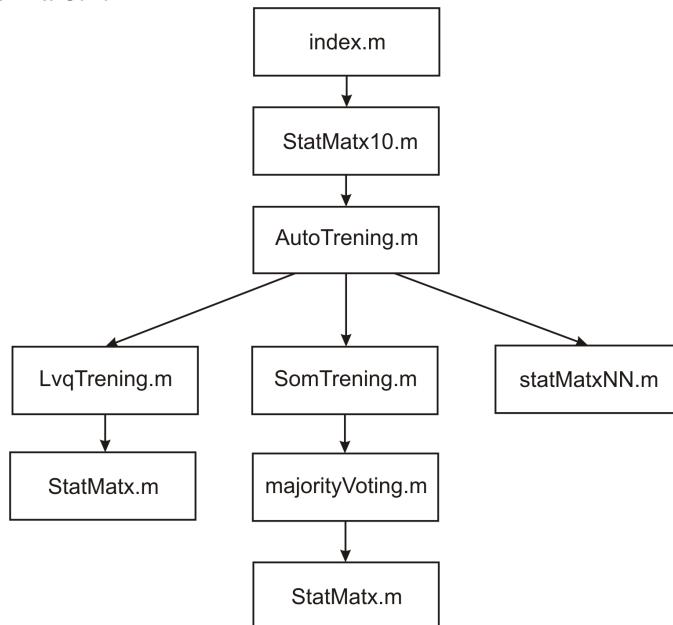
Kako je funkcionalnost izdvajanja obilježja na aero slikama ostvarena u programskom paketu Matlab, pokretanjem m-fajlova se dolazi do željenih ciljeva. Slijedi objašnjenje redoslijeda poziva m-fajlova u cilju realizovanja procesa klasifikacije. Kako je kod detaljno iskomentarisan ovdje neće biti uloženo u detalje realizacije. M-fajlovi su priloženi na CD-u.

M-fajl koji isjeca blokove 128x128 piksela sa ulazne aero slike koja je zadata za analizu nosi naziv *divider128x128.m*. Nazivi blokova se formiraju konkatenacijom riječi "blok" i rednog broj bloka. Blokovi su smješteni u folder annotatedTilesExpanded, iz kojih su pozivani po potrebi u ostalim m-fajlovima.

M-fajl *gabor.m*, generiše Gaborov filter na osnovu kog se formira banka filtara željene orientacije i skale, pozivom u *gabor\_generate.m*. *Fea\_Gabor\_brodatz.m* pozivom *gabor\_generate.m* kao izlaz daje vektor obilježja, tj. deskriptor tekture za proslijedenu sliku kao ulazni parametar. M-fajl *tex\_index\_annoTilesBL.m* uzastopnim pozivanjem *Fea\_Gabor\_brodatz.m* za svaki blok iz annotatedTilesExpanded foldera daje vektor obilježja te formira strukturu u kojoj bilježi naziv bloka i njegov deskriptor teksture. Struktura se snima u *signatures-annoTilesExpBL-128.mat* pošto će veoma često biti pozivana u ostalim m-fajlovima.

Slike 5.9, 5.10 i 5.11 su dobijene izvšavanjem *tex\_search\_annoTilesBL.m* fajla, koji pretragu vrši na osnovu snimljene strukture imena blokova i deskriptora teksture *signatures-annoTilesExpBL-128.mat*, a iscrtavanje 15 najблиžih blokova uz pomoć *tex\_thumbs\_annoTilesBL.m*.

Redoslijed pozivanja m-fajlova koji proračunavaju matrice konfuzije za realizacije klasifikatora sa SOM mrežom i LVQ mrežom ponaosob, kao i sa klasifikatorom baziranim na principu najbližeg susjeda (eng. Nearest Neighbor) je dat na slijedećoj blok šemi, slika 8.1.



Slika 8.1 – Redoslijed pozivanja m-fajlova za proračunavanje matrica konfuzije

Tok na slici 8.1 ne bavi se određivanjem klase jednog željenog bloka i prikazom prvih 15 blokova iz baze najbližih njemu po udaljenosti između deskriptora teksure. Ukoliko se žele vizuelno pokazati rezultati pretraživanja i klasifikacije to se ostvaruje jednim od slijedećih tokova poziva m-fajlova:

1. Ako se koristi klasifikator realizovan sa LVQ, prvo se trenira mreža na postojećim blokovima sa *lvqTrening\_annoTilesBL.m*. Zatim, m-fajl *klasifikator\_LVQ\_annoTilesBL.m* poziva *tex\_thumbs\_annoTilesBL\_klas.m* za iscrtavanje 15 najbližih blokova. M-fajl *tex\_thumbs\_annoTilesBL\_klas.m* koristi *ll.m* za proračunavanje pomenutih udaljenosti.
2. Ako se pak koristi SOM klasifikator, nakon treniranja mreže sa *somTrening\_annoTilesBL.m*, m-fajl *klasifikator\_SOM\_annoTilesBL.m* poziva onaj isti *tex\_thumbs\_annoTilesBL\_klas.m* za iscrtavanje 15 najbližih blokova.

Na izlazu u oba ova slučaja se ispisuje klasa kojoj pripada neuron koji je aktiviran na vektor obilježja zadane slike.

Ukoliko je potrebna klasifikacija nepoznate ulazne slike u sistem proizvoljne veličine, potrebno je pokrenuti m-fajl *divider128x128.m* koji snima blokove slike 128x128 piksela. U zavisnosti kojom je metodom potrebno klasifikovati dobijene blokove ulazne slike pokreće se *LVQClasificator.m* za LVQ klasifikator, *NNClasificator.m* za “Najbliži susjed” klasifikator dok je za SOM klasifikator prvo potrebno pokrenuti *SOMMajorityVoting.m*, a nakon njega *SOMClasificator.m*. Svi klasifikatori snimaju sliku u JPG formatu kao klasifikovanu varijantu slike na ulazu.