



UNIVERZITET CRNE GORE
ELEKTROTEHNIČKI FAKULTET



Milija Bajčeta

Primjena metoda vještačke inteligencije u segmentaciji krvnih sudova mrežnjače oka

– magistarski rad –

Podgorica, Septembar, 2017.

UNIVERZITET CRNE GORE
ELEKTROTEHNIČKI FAKULTET

Milija Bajčeta

**Primjena metoda vještačke inteligencije u
segmentaciji krvnih sudova mrežnjače oka**

– magistarski rad –

Podgorica, Septembar, 2017.

PODACI I INFORMACIJE O MAGISTRANTU

Ime i prezime: **Milija Bajčeta**

Datum i mjesto rođenja: 06.09.1992, Pljevlja

Prethodno završene studije:

Elektrotehnički fakultet, Elektronika, telekomunikacije i računari, 180 ECTS kredita, 2011

Elektrotehnički fakultet, Računari, 60 ECTS kredita, 2014

INFORMACIJE O MAGISTARSKOM RADU

Elektrotehnički fakultet

Studijski program: ETR-Računari

Naslov rada: **Primjena metoda vještačke inteligencije u segmentaciji krvnih sudova mrežnjače oka**

Mentor: Prof. dr Slobodan Đukanović

UDK, OCJENA I ODBRANA MAGISTARSKOG RADA

Datum prijave magistarskog rada: 16.03.2017.

Datum sjednice Vijeća na kojoj je prihvaćena tema: 29.05.2017.

Komisija za ocjenu teme i podobnosti magistranta:

1. Prof. dr Vesna Popović-Bugarin
2. Prof. dr Slobodan Đukanović
3. Doc. dr Nataša Popović

Komisija za ocjenu rada:

1. Prof. dr Vesna Popović-Bugarin
2. Prof. dr Slobodan Đukanović
3. Doc. dr Nataša Popović

Komisija za odbranu rada:

1. Prof. dr Vesna Popović-Bugarin
2. Prof. dr Slobodan Đukanović
3. Doc. dr Nataša Popović

Datum odbrane: 11.09.2017

Datum promocije:

Sadržaj

Sažetak	1
Abstract	2
1 Uvod	3
2 Algoritam kolonije mrava	8
2.1 Mravi u prirodi	9
2.2 Eksperiment sa dvokrakim mostom	9
2.3 Matematički model mrava	11
3 Neuralne mreže	13
3.1 Neuron	14
3.1.1 Funkcija mreže	15
3.1.2 Aktivaciona funkcija	15
3.2 Učenje mreže	16
3.2.1 Učenje sa nadgledanjem	17
3.2.2 Učenja bez nadgledanja	18
3.3 Topologija neuralne mreže	18
3.4 Sticanje znanje neuralne mreže	19
3.4.1 Adaptivni linearni sabirač	20
3.4.2 Neuron sa kontinualnim izlazom	21
3.4.3 Višeslojna mreža	22
4 Predloženi sistemi za segmentaciju krvnih sudova mrežnjače očnog dna	26
4.1 Morfološki operatori	26
4.2 Početna obrada slike	29
4.3 Računanje karakteristika	31
4.3.1 Linijski detektor	31
4.3.2 Linijski detektor sa ortogonalnom linijom	32

4.4	Primjena metoda vještačke inteligencije u predloženim sistemima	34
4.4.1	Algoritam kolonije mrava	35
4.4.2	Neuralna mreža	39
4.5	Završna obrada slike	40
4.6	Struktura sistema	43
4.6.1	Sistem sa algoritmom kolonije mrava	43
4.6.2	Sistem sa neuralnom mrežom	45
5	Rezultati	48
5.1	Algoritam kolonije mrava	56
5.1.1	Algoritam kolonije mrava sa linijskim detektorom	56
5.1.2	Algoritam kolonije mrava sa linijskim detektorom sa ortogonalnom linijom	60
5.1.3	Algoritam kolonije mrava sa kombinovanom karakteristikom	64
5.2	Neuralna mreža	70
6	Zaključak	75

Sažetak

Prepoznavanje oblika igra sve veću ulogu u današnjem svijetu i pronalazi primjenu u raznim disciplinama. U ovom radu je predstavljena primjena prepoznavanja oblika u medicinskim aplikacijama. Preciznije, rad se bavi primjenom dvije metode vještačke inteligencije za segmentaciju krvnih sudova mrežnjače očnog dna.

Segmentacija krvnih sudova mrežnjače očnog dna predstavlja prvi i veoma važan korak prilikom zdravstvene analize pacijenta na oboljenja koja se mogu odraziti na oko. Na mrežnjači očnog dna, to jest na krvnim sudovima i strukturama mrežnjače očnog dna se mogu uočiti prisustva raznih oboljenja, kao što su hipertenzija, dijabetes i kardiovaskularna oboljenja. Ručna segmentacija krvnih sudova mrežnjače očnog dna je naporan i dug proces koji zahtijeva dosta iskustva. Iz tog razloga, ovaj rad se bavi automatizacijom pomenutog procesa, odnosno predložena su dva sistema za automatizaciju segmentacije krvnih sudova mrežnjače očnog dna. Glavni dijelovi predloženih sistema su metode vještačke inteligencije na kojima je ostatak sistema baziran. Slike koje su korišćene za sprovođenje eksperimenta se nalaze u javno dostupnim bazama DRIVE i STARE.

Rezultati dobijeni prilikom testiranja sistema mogu se porebiti sa savremenim metodama u ovoj oblasti, to jest predloženi algoritmi bi se mogli koristiti kao smjernica prilikom analize zdravstvenog stanja pacijenta. Pored predloženih sistema, u radu su takođe detaljno objašnjene i dvije korišćene metode vještačke inteligencije: algoritam kolonije mrava i neuralne mreže.

Primjena metoda vještačke inteligencije za rešavanje navedenog problema igra veoma bitnu ulogu u medicini s obzirom da pomenuti proces predstavlja prvi i neizbjegni korak prilikom analize zdravstvenog stanja pacijenta na oboljenja koja se mogu odraziti na oko.

Ključne riječi: algoritam kolonije mrava, neuralne mreže, segmentacija krvnih sudova, linijski detektor, morfološki operatori.

Abstract

Pattern recognition plays an increasingly important role in today's world and finds its application in various disciplines. An example of pattern recognition usage in medical applications is presented in this paper. More precisely, the paper considers two artificial intelligence methods for retinal blood vessel segmentation.

Retinal blood vessel segmentation represents a very important first step in patient's health analysis for the purpose of detecting diseases that could be reflected on the eye. By looking at the retina, i.e. retinal blood vessels and retinal structure, the presence of various diseases such as hypertension, diabetes and cardiovascular diseases can be detected. Manual segmentation of retinal blood vessels is a laborious and time consuming process that requires plenty of experience. For that reason this paper concerns the automation of the aforementioned process, and two retinal blood vessel segmentation systems have been proposed. The main parts of the proposed systems are artificial intelligence methods which the systems are based on. The images used for the conducting of the experiments can be found in DRIVE and STARE image bases that are available online.

The results obtained during the testing of the system can be compared with the latest methods in this field of research, i.e. the proposed algorithms could be used as a valid directive in the process of patient's health condition analysis. Apart from the proposed system, the paper contains elaborate explanations of two other artificial intelligence methods: ant colony optimization algorithm and neural networks.

The usage of methods based on artificial intelligence for the solving of the aforementioned problems plays crucial role in medicine, considering that this process represents the first and inevitable step in the process of patient's health condition analysis which could reflect on the eye.

Key words: ant colony optimization algorithm, neural networks, blood vessel segmentation, line detector, morphological operators

Glava 1

Uvod

Prepoznavanje oblika (engl. *pattern recognition*) je naučna disciplina čiji je cilj klasifikacija objekata u određene klase [1–3]. Navedena definicija je jedna od mnogobrojnih definicija za prepoznavanje oblika. Zavisno od oblasti primjene, objekat koji se klasificuje može biti 1D signal, 2D signal ili bilo koja druga mjerljiva veličina.

Mnogobrojni su kriterijumi po kojima se pomenuti algoritmi mogu podijeliti na dvije i više grupe. Jedan od najčešće korišćenih kriterijuma na osnovu kojeg se vrši podijela jeste prema procesu učenja. Koristeći pomenuti kriterijum možemo razlikovati dvije grupe ovih algoritama [1–3]:

1. Algoritmi sa nadgledanjem (engl. *supervised algorithm*).
2. Algoritmi bez nadgledanja (engl. *unsupervised algorithm*).

Algoritmi sa nadgledanjem donose odluku o klasifikaciji ulaznog podatka u jednu od više klase na osnovu stečenog početnog znanja. Da bi algoritam stekao početno znanje potrebno je izvršiti treniranje sistema. Treniranje sistema se vrši koristeći podatke za obuku. Podaci za obuku obuhvataju ulazne podatke i definisane izlaze za date ulazne podatke. Na ovaj način, poređenjem dobijenog i željenog izlaza se vrši modifikacija koeficijenata (težinskih faktora) sistema u kojima je pohranjeno znanje sistema.

U slučaju kada podaci za obuku nisu dostupni koriste se algoritmi bez nadgledanja. Kod algoritama bez nadgledanja ne postoji početno znanje sistema, već sistem na osnovu ulaznih podataka donosi odluku u koju klasu da klasificuje ulazni podatak. Kod ove vrste algoritama praksa je da korisnik unaprijed zadaje broj klasa.

U današnjem društvu prepoznavanje oblika igra sve veću ulogu, pronalazi primjenu u raznim disciplinama u praksi kao što su: mašinska vizija, kompjuterska dijagnostika, prepoznavanje govora, finansijska predviđanja, prepoznavanje karaktera... U ovom radu ćemo se baviti prepoznavanjem oblika u kompjuterskoj dijagnostici. Kompjuterska dijagnostika se može primjeniti na velikom broju kompjuterskih snimaka: rendgenski, CT, ultrazvučni... U našem slučaju je u pitanju primjena metoda vještačke inteligencije na slike mrežnjače očnog dna [4–23]. Kod ovog vida prepoznavanja oblika, algoritmi pomažu ljekarima prilikom donošenja odluka, to jest ljekar mora uspostaviti dijagnozu, a algoritam mu služi kao smjernica.

Oftamologija je grana medicine koja se bavi bolestima oka, uključujući bolesti vidnog puta (sistema u mozgu koji je zadužen za vid). Na krvnim sudovima i strukturama mrežnjače očnog dna mogu se uočiti prve promjene koje ukazuju na razvoj ili postojanje raznih organskih oboljenja, kao što su dijabetes, povišeni krvni pritisak (hipertenzija), razna kardiovaskularna oboljenja... Automatizacija sistema, koji bi korišćenjem metoda vještačke inteligencije izvršio segmentaciju bolesti oka, se svodi na dvije aktivnosti:

1. Automatizacija detekcije krvnih sudova.
2. Određivanje karakteristika krvnih sudova na osnovu kojih bi se donosila odluka o zdravstvenom stanju pacijenta.

Ručna detekcija krvnih sudova mrežnjače očnog dna i njihovo izdvajanje iz slike predstavlja težak i dug posao koji zahtjeva dosta treninga i vještine. Zbog toga je automatizacija detekcije krvnih sudova mrežnjače očnog dna prvi i veoma važan korak u medicinskoj dijagnostici prilikom donošenja odluke o zdravstvenom stanju pacijenta.

Postoje mnogi algoritmi u literaturi za detekciju krvnih sudova mrežnjače očnog dna. Dvije najčešće korišćene kategorije algoritama su: klasifikacija oblika i mašinsko učenje (eng. *pattern classification and machine learning*), prilagođeni filtri (eng. *matched filtering*).

Algoritmi koji spadaju u kategoriju algoritama klasifikacije oblika i mašinskog učenja su najčešće korišćene algoritme u ovoj oblasti [4]. Pomenuti algoritmi vrše klasifikaciju nad pikselima, odnosno posmatrani piksel se stavlja u jednu od dvije klase: krvni sud ili pozadina. Klasifikacija se vrši uz pomoć karakteristika koje se izvlače iz slike. Algoritmi u ovoj oblasti se mogu podijeliti u već pomenute dvije grupe algoritama za prepoznavanje oblika: algoritmi sa nadgledanjem i algoritmi bez nadgledanja.

Druga najčešće korišćena kategorija algoritama u ovoj oblasti su prilagođeni filtri [4]. Primjenom ovih algoritama vrši se filtriranje slike sa maskom koja je dizajnirana da predstavlja karakteristike [4, 6, 7]. Osobine koje se najčešće koriste prilikom pravljenja maske kod prilagođenih filtera u detekciji krvnih sudova mrežnjače očnog dna su: zakriviljenost krvnih sudova, debljina krvnih sudova i vrijednost piksela poprečnog presjeka linije koji se može aproksimirati Gausovom krivom.

U ovom radu se bavimo rešavanjem problema automatizacije krvnih sudova mrežnjače očnog dna koristeći dvije metode:

1. Algoritam kolonije mrava (eng. *ant colony algorithm*) [24, 25].
2. Neuralne mreže (eng. *neural network*) [26–28].

Za treniranje i testiranje sistema korištene su slike iz javno dostupne DRIVE¹ (engl. *Digital Retinal Images for Vessel Extraction*) baze, Slika 1.1. [29]. Testiranje sistema je izvršeno i na javno dostupnoj STARE (engl. *Structured Analysis of the Retina*)² bazi, Slika 1.2. [30].

DRIVE baza se sastoji od:

1. Trening slika: RGB slike mrežnjače očnog dna koje se koriste za treniranje sistema u slučaju da se primjenjuje neki od algoritama sa nadgledanjem.
2. Testnih slika: RGB slike mrežnjače očnog dna koje se koriste za testiranje sistema.
3. Ručno obrađenih slika: specijalisti iz oblasti medicine su ručno izvršili segmentaciju krvnih sudova mrežnjače očnog dna trening i testnih slika. Ove slike se koriste za treniranje sistema i provjeru ispravnosti prilikom testiranja sistema. Trening slike su segmentirane od strane jednog stručnjaka, dok su testne slike segmentirane od strane dva stručnjaka.
4. Maske: koriste se da bi se izdvojila mrežnjača očnog dna od pozadine. Prilikom obrade slike obrađuje se samo dio koji se nalazi unutar maske. Veličina maske, odnosno mrežnjače očnog dna na slici zavisi od tipa kamere, to jest ugla pogleda kamere (engl. *field-of-view (FOV)*). FOV predstavlja širinu ugla pod kojim snima kamera i prilikom obrade slike obrađuju se pikseli koji se nalaze unutar FOV-a.

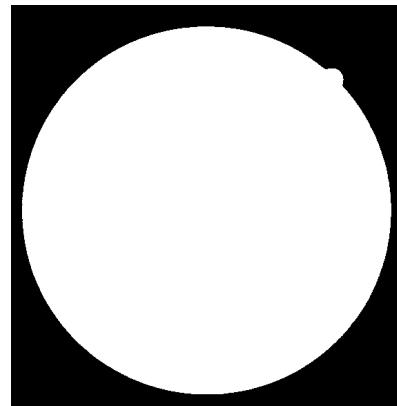
¹DRIVE baza je dostupna na adresi: <http://www.isi.uu.nl/Research/Databases/DRIVE/>

²STARE baza je dostupna na adresi: <http://cecas.clemson.edu/~ahoover/stare/>

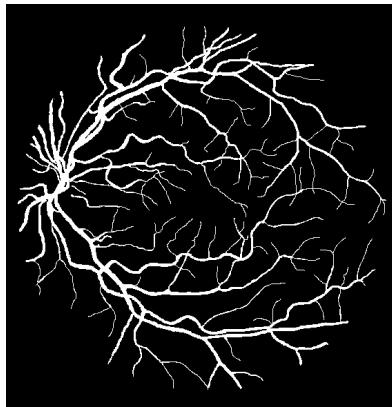
DRIVE baza se sastoji od 20 trening slika i 20 testnih slika rezolucije 768×584 dobijenih sa kamerom "Canon CR5 non-mydiatic 3-CCD" čiji je FOV 45° .



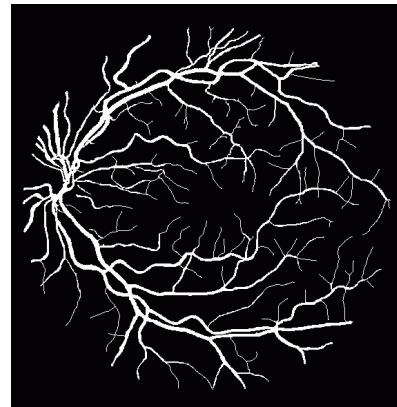
(a) Originalna slika.



(b) Maska.



(c) Ručno segmentirana slika (Stručnjak 1.)



(d) Ručno segmentirana slika (Stručnjak 2.)

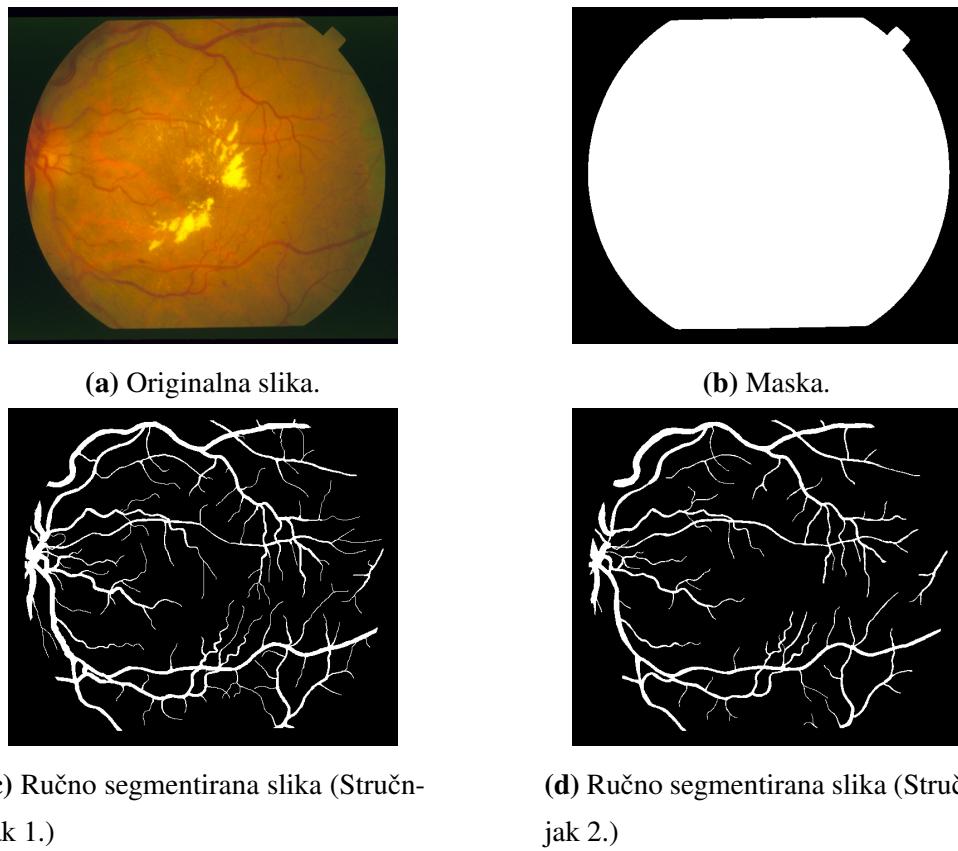
Slika 1.1: DRIVE baza (slike preuzete sa [29]).

STARE baza se sastoji od:

1. Trening slika: RGB slike mrežnjače očnog dna.
2. Testnih slika: RGB slike mrežnjače očnog dna.
3. Ručno obrađenih slika: trening slike imaju odgovarajuće ručno obrađene slike od strane dva stručnjaka i one su korištene prilikom testiranje sistema.
4. Maske.

Trening dio STARE baza koji je nama od interesa se sastoji od 20 slika, gdje je 10 slika od oboljelih pacijenata, to jest od pacijenata koji imaju neko od oboljenja koje se manifestuje

na mrežnjači očnog dna. Slike u STARE bazi su dobijene kamerom “TopCon TRV-50 fundus” sa FOV-om od 35° , dok je rezolucija 605×700 piksela.



Slika 1.2: STARE baza (slike preuzete sa [30]).

Glava 2

Algoritam kolonije mrava

U ovoj sekciji biće objašnjen algoritam kolonije mrava koji je jedan od najznačajnijih algoritama inteligentnih rojeva (engl. *swarm intelligent system*). Pomenuti algoritmi se koristi za rešavanje problema koji se mogu svesti na probleme pronalaženja putanje kroz graf. Razlog zbog kojeg su algoritmi inteligentnih rojeva našli primjenu jeste prilikom pretraživanja velikih grafova gdje postoji preveliki broj kombinacija, jer bi primjena determinističkih metoda zahtijevala dosta vremena za pronalaženje svih kombinacija.

Deneubourg-ov eksperiment 1990. godine sa mravima i dvokrakim mostom između glijezda i hrane je bio uvod da Marco Dorigo 1992. godine u svom doktoratu uvede pojam algoritma kolonije mrava [25]. Na početku je algoritam primjenjivan na problem putujućeg trgovca i problem kvadratnog pridruživanja, a od 1995. godine proširen je na razne probleme.

Danas se algoritam kolonije mrava primjenjuje prilikom rešavanja statičkih i dinamičkih problema. Statički problemi su problemi kod kojih se karakteristike zadaju jednom, na početku, i ne mijenjaju se tokom vremena. Klasičan primjer statičkog problema je problem putujućeg trgovca. Kod ovog problema lokacija gradova i udaljenost između gradova se ne mijenja tokom vremena. S druge strane, u slučaju dinamičkih problema, sami problem se mijenja tokom vremena. Ruturanje mreže je primjer dinamičkog problema gdje se topologija mreže i opterećenje linkova mijenja tokom vremena.

2.1 Mravi u prirodi

Istraživanje načina ponašanja mrava u prirodi omogućilo je razvoj raznih metoda za pronalaženje optimalnih putanja između dvije tačke grafa. Mravi prilikom pronalaženja hrane u prirodi iza sebe ostavljaju trag feromona, koji vremenom isparava. Drugi mravi prate trag feromona i na taj način dolaze do cilja. Ukoliko negdje osjete dva ili više tragova feromona odlučuju se za jači trag. Jačina traga feromona zavisi od dva faktora. Prvi je isparavanje feromona, to jest što je više vremena prošlo od postavljanja feromona to je trag slabiji. Shodno tome, hrana koja je više udaljena od gnijezda ima manju šansu da bude praćena u odnosu na neku bližu. Drugi faktor jeste broj mrava koji su već pratili određeni trag i postavili feromon, to jest što se više mrava prethodno odlučilo za jedan trag to je veća vjerovatnoća da je odabrani trag dobar.

Na Slici 2.1. je prikazana potraga mrava za hranom u prirodi:

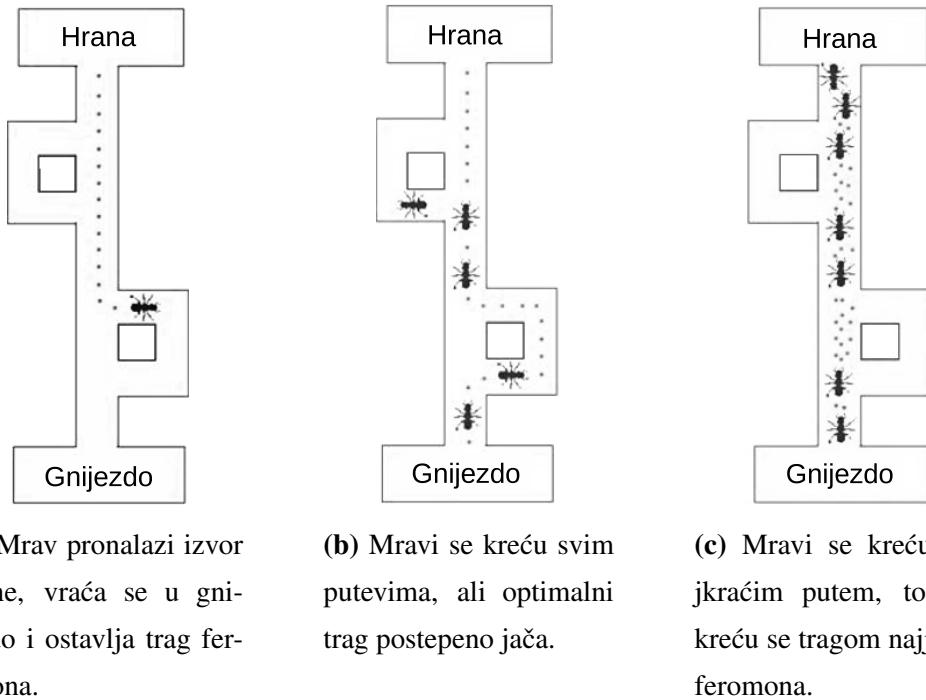
- (a) Mravi se kreću nasumično u potrazi za hranom. Nakon pronalaska hrane vraćaju se u gnijezdo ostavljajući za sobom trag feromona koji vremenom isprava.
- (b) Mravi se i dalje kreću nasumično, ali optimalni trag feromona je sve jači jer se njime kreće sve veći broj mrava.
- (c) Svi mravi se kreću najkraćim putem, ostali tragovi polako isparavaju.

2.2 Eksperiment sa dvokrakim mostom

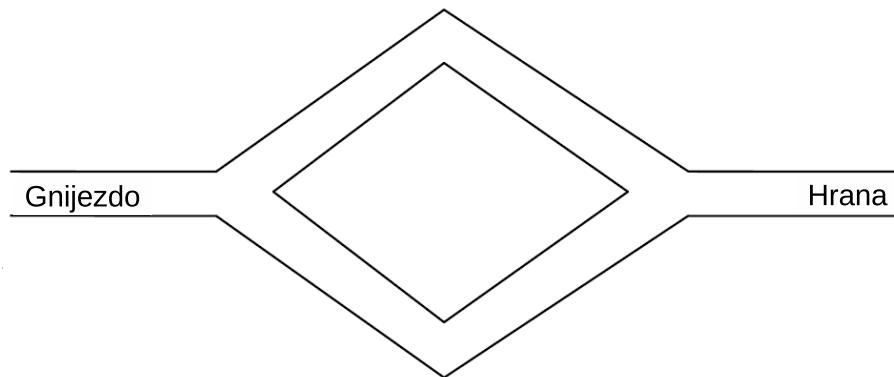
Eksperiment je zasnovan na pronalaženju optimalne putanje između hrane i gnijezda. Mravima su bile na raspolaganju dvije putanje, dvokraki most. Za eksperiment su korišćena dva dvokraka mosta:

1. Most kod kojeg su kraci dužine l_1 i l_2 u odnosu $r = \frac{l_1}{l_2} = 1$.
2. Most kod kojeg su kraci $r = \frac{l_1}{l_2} = 2$.

U prvom slučaju, Slika 2.2., dužine kraka su iste. Na početku su mravi slučajno birali put, a zatim nakon određenog vremena jednim krakom slučajno krene veći broj mrava. Na taj način više se feromona polaže na jedan krak. Nakon toga, sve veći i veći broj

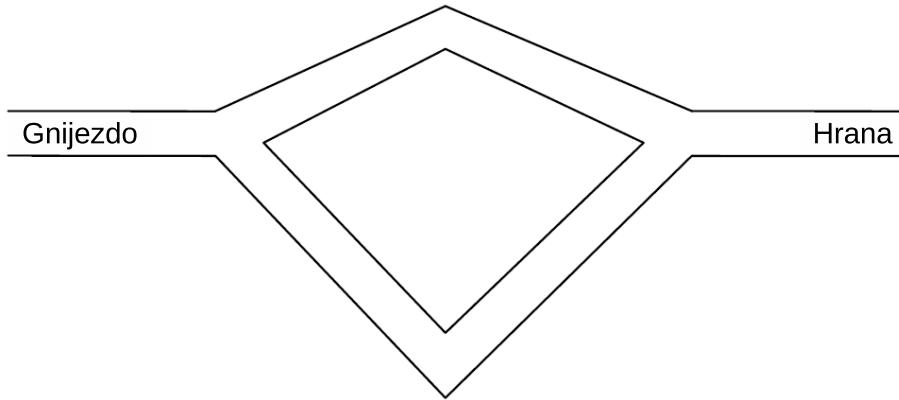
**Slika 2.1:** Prikaz mrava u potrazi za hranom.

mrava počinje da se kreće krakom jačeg feromona. Posle određenog vremena, svi mravi se kreću putem jačeg feromona, to jest slučajno odabranim krakom na početku.

**Slika 2.2:** Dvokraki most, $r = 1$.

U drugom slučaju, Slika 2.3., dužine kraka su u odnosu $r = 2$. Na početku se vrši slučajan izbor put, a zatim nakon određenog vremena kraćim krakom će da se kreće sve veći broj mrava. Razlog zbog kojeg je to tako je što će kraćim krakom mravi brže da stižu od hrane do gnezda i količina feromona ne tragu će da raste. S obzirom da se na kraćem kraku nalazi veća količina feromona posle određenog vremena mravi će da se

kreću kraćom putanjom.



Slika 2.3: Dvokraki most, $r = 2$.

2.3 Matematički model mrava

Mravi u prirodi pronalaze najkraći put između hrane i gnijezda koristeći trag feromona. Tokom kretanja od hrane do gnijezda mrav polaže feromon i prati ostale tragove feromona. U slučaju virtualnih mrava, mravi se postavljaju na slučajno odabранe pozicije (u našem slučaju bi to bili slučajno odabrani pikseli). Narednu akciju, to jest korak, mrav bira na osnovu vjerovatnoće $P_{(i,j)}$:

$$P_{(i,j)} = \frac{\Lambda(\sigma_{(i,j)})\Omega(\varphi_{(i,j)})}{\sum_{m=i-1}^{i+1} \sum_{n=j-1}^{j+1} \Lambda(\sigma_{(m,n)})\Omega(\varphi_{(m,n)})}, \quad (2.1)$$

gdje $\Lambda(\sigma)$ predstavlja funkciju količine feromona σ u posmatranom polju (našem slučaju pikselu), dok $\Omega(\varphi)$ predstavlja funkciju heuristike φ do posmatranog polja.

Nakon što posjeti polja, mrav ostavlja feromon u istom. Količina feromona koju virtualni mrav ostavi zavisi do tipa problema koji riješavamo, to jest načina izbora optimalne putanje.

Takođe, na startu svaki mrav posjeduje istu količinu energije. Tokom iteracija, to jest kretanja mrava, energija opada sa ciljem da ostavi u životu samo mrave koji se kreću optimalnim putanjama.

Na kraju svake iteracije dolazi do globalnog isparenja feromona, to jest od ukupne količine feromona u svakom polju se oduzima konstantni dio feromona koji u stvari pred-

stavlja isparavanje feromona u prirodi. Na ovaj način se odbacuju putanje koje nisu optimalne, to jest putanje kojima više ne idu mravi.

U nastavku slijedi pseudokod algoritma kolonije mrava:

Algoritam 1 Algoritam kolonije mrava

- 1: Postavljanje mrava na slučajno odabране pozicije
 - 2: **for** iteracije **do**
 - 3: **for** kretanje po mravima **do**
 - 4: Odabir naredne akcije, formula (2.1)
 - 5: Polaganje feromona u posjećeno polje
 - 6: Opadanje energije mrava
 - 7: Globalno isparenje feromona
-

Glavna razlika između mrava u prirodi i virtualnih mrava je što virtualni mravi sadrže informaciju o prethodnoj akciji. Takođe virtualni mravi imaju smjernice (heuristiku) koju pored feromona koriste prilikom donošenja odluke o akciji, pa se virtualni mravi na samom početku slučajno postavljaju na pozicije ali odmah počinju da se kreću na osnovu smjernica, a ne nasumično. Još jedna bitna razlika između virtualnih mrava i mrava u prirodi je što mravi u prirodi nakon pronalaska hrane kreću sa ostavljanjem feromona, dok virtualni mravi od samog starta kreću sa ostavljanjem feromona.

Glava 3

Neuralne mreže

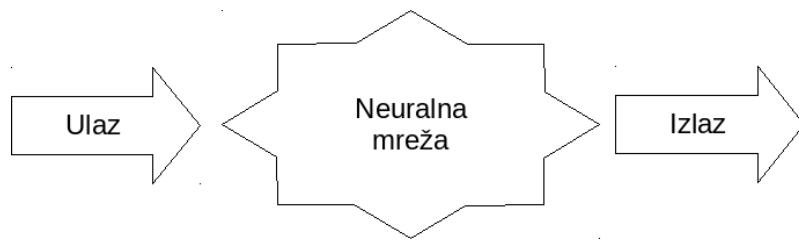
Danas većina podataka koje ne obrađujemo svojim umom obrađujemo računarom, ali bez obzira na to i dalje se najveća količina podataka obrađuje umom. Razlog zbog kojeg ljudski um i dalje obrađuje veću količinu podataka od računara je u samoj strukturi računara. Računari su napravljeni da funkcionišu po tačno određenim pravilima i sekvencialno obrađuju podatke.

U cilju rešavanja ovog problema postoji oblast nauke koja se bavi imitacijom ljudskog mozga i naziva se vještačka inteligencija. Cilj je napraviti sistem koji vrši paralelnu obradu podataka kako bi se simulirao rad ljudskog mozga. Sistem bi trebao da donosi ispravnu odluku na osnovu sopstvenog znanja koje je stekao učenjem.

Ljudski mozak se sastoji od velikog broja neurona koji rade paralelno prilikom obrade podataka. Slično tome, vještačke neuralne mreže, ili samo neuralne mreže, predstavljaju pojednostavljen model ljudskog mozga. Ideja se javila 1940. godine kada McCulloch i Pitts (*Massachusetts Institute of Technology*) objavljaju matematički model neuralne mreže [26]. Tadašnji računari nisu bili dorasli implementaciji neuralne mreže, pa tek krajem pedesetih godinajavljaju se prva praktična ostvarenja neuralnih mreža. Zatim neuralne mreže opet padaju u zaborav sve do devedesetih godina kada postaju opet nezaobilazni koncept pri razvoju inteligentnih sistema.

Neuralna mreža predstavlja vještački ćelijski sistem sposoban da prihvati, obradi, upamtiti i primjeni svoje znanje kako bi dao odgovor na dovedeni ulazni podatak.

Osnovni element svake neuralne mreže je neuron. Neuron predstavlja osnovnu jedinicu za obradu podataka u neuralnoj mreži. Veze između neurona su jednosmjerne, to

**Slika 3.1:** Neuralna mreža.

jest izlazni podaci jednog neurona predstavljaju ulazne podatke drugog neurona.

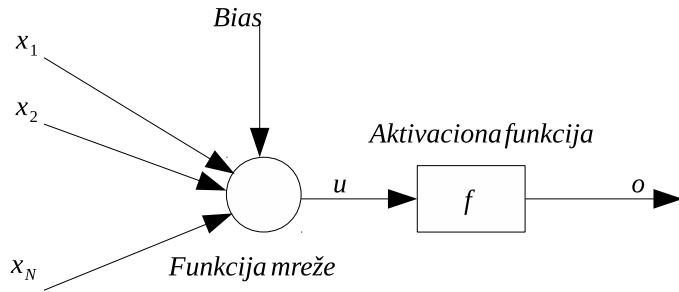
3.1 Neuron

Prvi korak prilikom modelovanja neurona jeste modelovanje ulaza i izlaza. Ulazne i izlazne informacije u biološkim sistemima su električni potencijali koji se mogu numerički modelovati. Isti princip je primjenjen u vještačkim neuralnim mrežama.

McCulloch-Pitts model neurona ulazni signal predstavlja numerički i množi sa težinskim faktorima (koeficijentima), a zatim vrši sumiranje i poređenje izlaza sa funkcijom praga. Težinski faktori predstavljaju znanje sistema. Ovakav tip neurona, sa binarnim izlazom, predstavlja perceptron. Perceptron se u osnovnom slučaju sastoji samo od jednog neurona, mada može i da se sastoji od više neurona koji čine jednoslojnu neuralnu mrežu sa M izlaza (broj izlaza je jednak broju neurona). Ovo je slučaj kada za ulazni podatak utvrđujemo da li ima neku od M osobina, odnosno ulazni podatak klasifikujemo u jednu od M klasa.

Dakle, neuron definiše pravila računanja jednog izlaza na osnovu N ulaza. Kod McCulloch-Pitts model neurona suma proizvoda težinskih faktora i ulaznih podataka predstavlja argument funkcije koja se naziva aktivaciona funkcija. Funkcija praga je jedan vid aktivacione funkcije. Prema tome postupak dobijanja izlaza na osnovu ulaza dijeli na dva dijela, Slika 3.2.:

1. Funkcija mreže.
2. Aktivaciona finkcija.



Slika 3.2: Neuron.

3.1.1 Funkcija mreže

Funkcija mreže sadrži znanje sistema i ona vrši kombinaciju ulaznih veličina. U Tabeli 3.1. su predstavljene funkcije mreže [27].

Tabela 3.1: Funkcije mreže.

Naziv	Funkcija
Linearna	$u = \sum_{i=1}^N w_i x_i + \Theta$
Linearna forma II reda	$u = \sum_{i=1}^N \sum_{k=1}^N w_{ik} x_i x_k + \Theta$
Proizvod	$u = \prod_{i=1}^N x_i^{w_i}$

Zbog svoje jednostavnosti najčešće korišćen tip funkcije mreže je linearna.

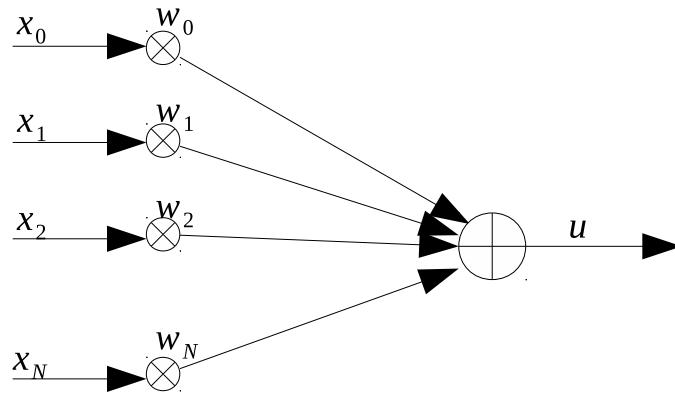
Izlaz neurona pored ulaza zavisi i od stanja samog neurona Θ . Stanje neurona se naziva "bias". Neuron sa linearnom funkcijom mreže i nenultim bias-om se može pojednostaviti tako što se posmatra $x_0 = 1$, pa se u tom slučaju bias može modelovati sa w_0 , Slika 3.3.

U ovom radu je korišćena linearna funkcija mreže sa nenultim bias-om.

3.1.2 Aktivaciona funkcija

Zadatak aktivacione funkcije jeste da izlaz funkcije mreže transformiše u željeni izlaz sistema. U Tabeli 3.2. su predstavljene aktivacione funkcije [27].

Dvije najznačajnije aktivacione funkcije su unipolarna funkcija praga i unipolarni sigmoid. U ovom radu je kao aktivaciona funkcija korišćena unipolarni sigmoid.



Slika 3.3: Linearna funkcija mreže.

Tabela 3.2: Aktivacione funkcije.

Naziv	Funkcija
Linearna	$f(u) = u$
Limiter	$\begin{cases} 1 & \text{ako } u > 1, \\ u & \text{ako } -1 \leq u \leq 1, \\ -1 & \text{ako } u < -1. \end{cases}$
Funkcija praga (unipolarna)	$\begin{cases} 1 & \text{ako } u > 0, \\ 0 & \text{ako } u < 0. \end{cases}$
Funkcija praga (bipolarna)	$\begin{cases} 1 & \text{ako } u > 0, \\ -1 & \text{ako } u < 0. \end{cases}$
Sigmoid (unipolarni)	$f(u) = \frac{1}{1+e^{-u}}$
Sigmoid (bipolarni)	$f(u) = \frac{2}{1+e^{-2u}} + 1$
Arkus tanges	$f(u) = \frac{2}{\pi} \arctan(u)$
Gausova funkcija	$f(u) = e^{(\frac{(u-m)^2}{\sigma})}$

3.2 Učenje mreže

Znanje sistema, to jest dobijanje izlaza u funkciji ulaza, sadržano je u koeficijentima sistema. Koeficijenti sistema se kroz postupak učenja prilagođavaju kako bi dali izlaz koji zadovoljava postavljene kriterijume. Učenje je iterativni postupak dobijanja izlaza na osnovu ulaznih podataka.

Na osnovu kriterijuma da li nam je poznat izlaz sistema prilikom treniranja neuralne mreže razlikujemo dva načina treniranja:

1. Učenje sa nadgledanjem - učenje mreže sprovodi se sa parovima (ulaz,izlaz).
2. Učenje bez nadgledanja - mreža uči bez poznavanja izlaza.

3.2.1 Učenje sa nadgledanjem

Proces treniranja mreže sa nadgledanjem se sastoji od sledećih koraka:

1. Prikupljanje podataka za treniranje. Podaci za treniranje se sastoje od parova (ulaz, izlaz), pri čemu se izlazni podaci dobijaju ekspertizom. Na ovaj način jedan od faktora koji direktno utiče na tačnost sistema jeste stručnjak koji daje ekspertizu. Podaci za obuku predstavljaju konačan skupu podataka.
2. Nakon prikupljanja podataka za obuku vrši se inicijalizacija mreže. Inicijalizacija mreže se vrši tako što neuroni slučajno uzimaju svoje koeficijente, to jest slučajno im se dodjeljuje početno znanje. Nakon toga se pristupa iterativnom postupku treniranja mreže:
 - (a) Uzima se jedan par (ulaz, izlaz) i na osnovu ulaznih podataka računa se izlaz. U slučaju da je dobijeni izlaz jednak željnom izlazu koeficijenti mreže ostaju nepromjenjeni, dok u slučaju kada dobijeni izlaz odstupa od željenog izlaza vrši se modifikacija koeficijenata mreže.
 - (b) Uzima se naredni par (ulaz, izlaz) i ponavlja se prethodni korak. Kada svi parovi (ulaz, izlaz) prođu jednom kroz mrežu završena je jedna epoha treniranja.
 - (c) Razmatraju se rezultati poslednje epohe. U slučaju da su svi parovi (ulaz, izlaz) zadovoljili kriterijum, treniranje je završeno. U slučaju da rezultati nisu zadovoljavajući, vraćamo se na početak iterativnog postupka.

Iterativni postupak ne mora uvijek dovesti do konvergencije mreže, pa se pristupa nekom od sledećih koraka:

1. Ponovno treniranje mreže sa drugačjom inicijalizacijom polaznih koeficijenata.

2. Mijenjanje strukture mreže.
3. Između parova (ulaz, izlaz) ne postoji zavisnost, to jest karakteristike koje smo odabrali da prezentuju ulazne podatke ne vrše dobro njihovu prezentaciju koja bi jednoznačno ukazivala na željeni izlaz. U ovom slučaju se traže nove karakteristike koje će na bolji način prezentovati ulazne podatke.

3.2.2 Učenja bez nadgledanja

U slučaju učenja bez nadgledanja, u idealnim uslovima broj izlaznih neurona je jednak broju kategorija (klasa) u koje treba da se klasifikuju ulazni podaci. Svaki od neurona prepoznaće po jednu kategoriju nakon određenog vremena treniranja. U slučaju da dva neurona prepoznaju jednu klasu potrebno je jedan neuron eliminisati, dok u slučaju da klasa ostane neprepoznata potrebno je dodati neuron.

U ovom radu je korišćeno učenje mreže sa nadgledanjem.

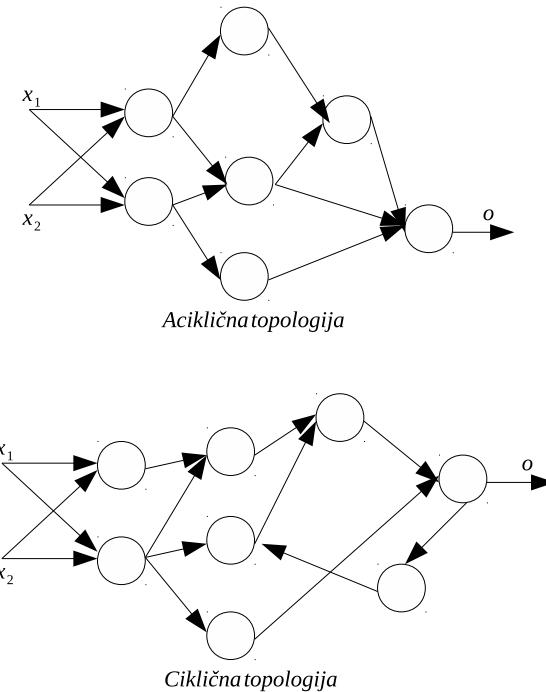
3.3 Topologija neuralne mreže

Neuralna mreža se sastoji od većeg broja neurona koji su povezani sa ulaznim podacima i međusobno u cilju dobijanja izlaza. U zavisnosti od toga da li neuralna mreža sadrži zatvorenu konturu ili ne, razlikujemo ciklične i aciklične neuralne mreže.

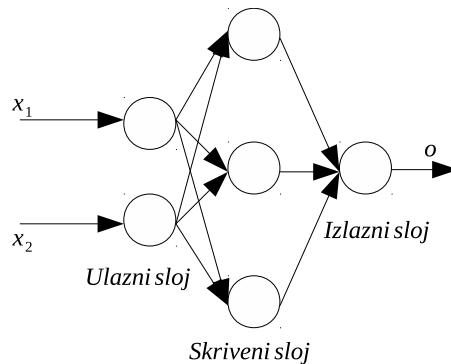
Posebna podgrupa acikličnih neuralnih mreža jesu mreže kod kojih se neuroni mogu grupisati u slojeve. Izlazi neurona iz jednog sloja predstavljaju ulaze za neurone u sledećem sloju. Kod ovih mreža razlikujemo tri tipa sloja:

1. Ulazni sloj.
2. Skriveni sloj.
3. Izlazni sloj.

Ulazni sloj ne vrši obradu podataka, već samo prosleđuje podatke sa ulaza na izlaz prema neuronima u prvom skrivenom sloju, dok druga dva tipa sloja vrše obradu podataka. Ovakva struktura mreže je korišćena prilikom rešavanja našeg problema.



Slika 3.4: Topologija neuralne mreže.



Slika 3.5: Višeslojna neuralna mreža.

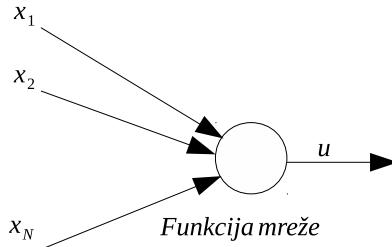
3.4 Sticanje znanje neuralne mreže

Kao što smo već rekli, neuron predstavlja osnovnu jedinicu neuralne mreže. Neuron se sastoji od funkcije mreže i može, a i ne mora imati aktivacionu funkciju.

U ovoj sekciji ćemo objasniti način dobijanja koeficijenata najjednostavnijeg primjera neurona (adaptivni linearni sabirač), to jest na koji način neuron stiče znanje koje je pohranjeno u njegovim koeficijentima. Zatim ćemo preći na strukturu neurona koje smo mi koristili prilikom kreiranja neuralne mreže i način njihovog sticanja znanja.

3.4.1 Adaptivni linearne sabirač

Posmatrajmo najjednostavniji primjer neurona koji se sastoji samo od linearne funkcije mreže i naziva se *adaptivni linearni sabirač*, Slika 3.6.



Slika 3.6: Adaptivni linearni sabirač.

Označimo sa W koeficijente neurona, dok X predstavlja ulazne podatke u neuron.

$$W = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_N \end{bmatrix}$$

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_N \end{bmatrix}$$

Tada je izlaz neurona:

$$u = W^T X. \quad (3.1)$$

Greška u k -tom koraku treniranja je:

$$\varepsilon_k = d_k - u_k, \quad (3.2)$$

gdje d_k predstavlja željeni izlaz sistema u k -tom koraku.

Da bi se minimizovala kvadratna greška:

$$E_k = \frac{1}{2} \varepsilon_k^2 \quad (3.3)$$

$$E_k = \frac{1}{2} (d_k - u_k)^2 \quad (3.4)$$

$$E_k = \frac{1}{2} (d_k - \sum_{i=1}^N w_i x_i)^2, \quad (3.5)$$

potrebno je modifikovati koeficijente neurona. Konstanta $\frac{1}{2}$ nema bitan uticaj i uvedena je da bi se pojednostavio matematički aparat prilikom računanja koeficijenata neurona.

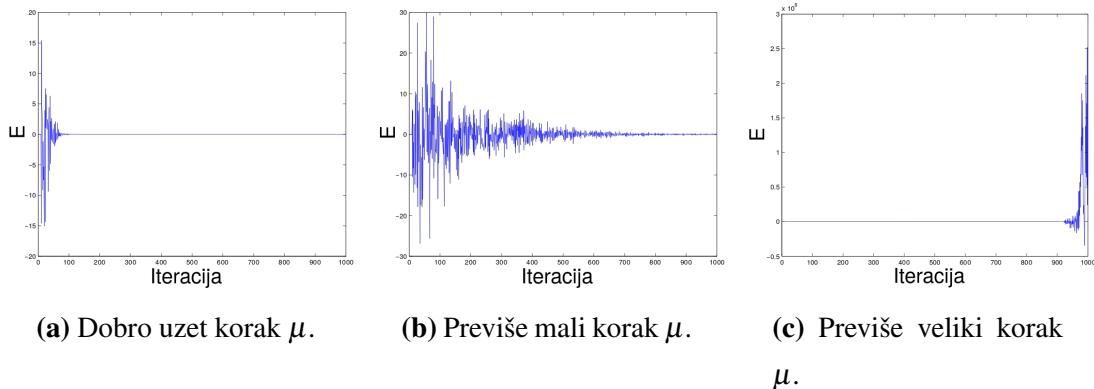
Modifikaciju koeficijenata neurona vršimo primjenom LMS algoritma [27]:

$$W_{k+1} = W_k - \mu \frac{\partial E_k}{\partial W} \quad (3.6)$$

$$W_{k+1} = W_k + \mu \epsilon_k X_k, \quad (3.7)$$

gdje μ predstavlja koeficijent učenja.

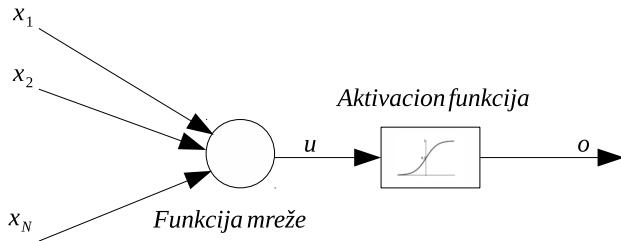
Treba napomenuti da se do formula za koeficijente LMS algoritama došlo polazeći od metode najbržeg sruštanja, gdje μ predstavlja korak sruštanja. Na osnovu toga može se lako zaključiti da se uzimanjem velikog koraka μ dovodi do divergencije, jer nikad nećemo moći tačno da dođemo do rešenja. U drugom slučaju, uzimanje isuviše malog koraka μ dovodi do previše iteracija, odnosno dovodi do isuviše spore konvergencije. Najbolji pokazatelj koliko je dobro izabran korak μ je kvadratna greška E tokom iteracija, Slika 3.7.



Slika 3.7: Kvadratna greška za različit izbor koraka μ .

3.4.2 Neuron sa kontinualnim izlazom

Za razliku od adaptivnog linearne sabirača, koji se sastoji samo od linearne funkcije mreže, mi smo koristili neurone koji se sastoje od linearne funkcije mreže i aktivacione funkcije unipolarnog sigmoida, Slika 3.8.



Slika 3.8: Neuron sa aktivacionom funkcijom unipolarni sigmoid.

Na identičan način kao kod adaptivnog linearног sistema koeficijenti mreže se modifikuju kako bi se smanjila kvadratna greška, formula (3.6), s tim što je:

$$\varepsilon_k = d_k - f(u) = d_k - o_k, \quad (3.8)$$

pa je kvadratna greška:

$$E_k = \frac{1}{2}(d_k - o_k)^2 = \frac{1}{2}(d_k - f(\sum_{i=1}^N w_i x_i))^2. \quad (3.9)$$

Na osnovu formule (3.9) možemo izračunati:

$$\begin{aligned} \frac{\partial E_k}{\partial W} &= -(d_k - o_k) \frac{\partial o_k}{\partial W} = -(d_k - o_k) f'(\sum_{i=1}^N w_i x_i) X_k \\ f'(u) &= \frac{\partial}{\partial u} \frac{1}{1 + e^{-u}} = f(u)(1 - f(u)), \end{aligned} \quad (3.10)$$

pa je:

$$\frac{\partial E_k}{\partial W} = -(d_k - o_k) o_k (1 - o_k) X_k. \quad (3.11)$$

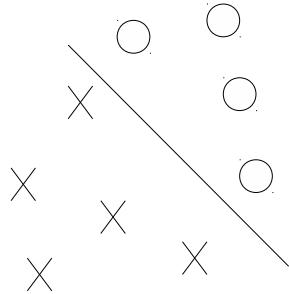
Koristeći formule (3.6) i (3.11) dobijamo:

$$W_{k+1} = W_k + \mu(d_k - o_k)o_k(1 - o_k)X_k. \quad (3.12)$$

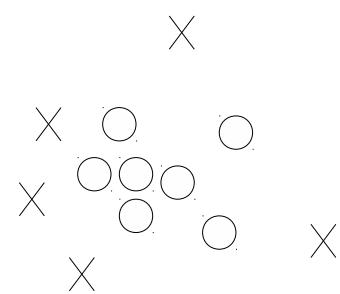
Neuronom sa linearnom funkcijom mreže i pragom kao aktivacionom funkcijom možemo riješiti probleme koji su linearno odvojeni, Slika 3.9a., dok primjenom sigmoida kao aktivacione funkcije možemo smanjiti grešku kod linearно neodvojivih problema, Slika 3.9b. Da bi na bolji način razdvojili linearne neodvojive probleme potrebno je koristiti neuralnu mrežu sa sigmoidom kao aktivacionom funkcijom.

3.4.3 Višeslojna mreža

Višeslojna mreža predstavlja mrežu koja sadrži bar jedan skriveni sloj. Prilikom treniranje mreže postoje parovi (ulaz, izlaz), dok informacije o izlazu iz skrivenih slojeva



(a) Linearno odvojiv problem.

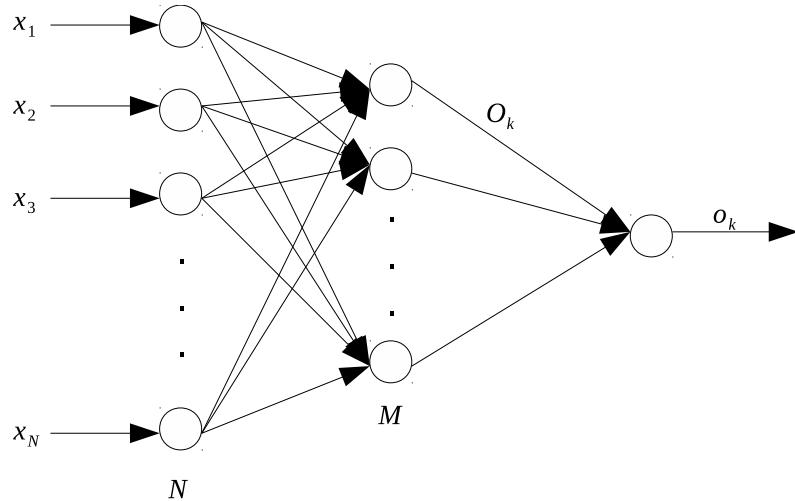


(b) Linearno neodvojiv problem.

Slika 3.9: Linearna odvojenost problema

nemamo. Najčešće korišćen pristup prilikom treniranja neuralnih mreža je učenje unazad (eng. "*backpropagation learning*"). Kod ove metode, greška na izlazu jednog nivoa se inverznim putem vraća na grešku na izlazu prethodnog nivoa. A kao što je već rečeno, na osnovu greške na izlazu neurona se vrši modifikacija koeficijenata neurona.

Posmatrajmo sada primjer neuralne mrežu sa N ulaza, M neurona u skrivenom sloju i jednim neuronom u izlaznom sloju, Slika 3.10. Svaki neuron se sastoji od linearne funkcije mreže i unipolarnog sigmoida kao aktivacione funkcije.

**Slika 3.10:** Neuralna mreža.

Neuroni ulaznog sloja prosleđuju ulazne podatke ka skrivenom sloju. Neka su W

koeficijenti neurona u skrivenom sloju, a V koeficijenti izlaznog neurona.

$$W = \begin{bmatrix} w_{11} & w_{12} & w_{13} & \dots & w_{1N} \\ w_{21} & \ddots & & & \\ w_{31} & & & & \\ \vdots & & & & \\ w_{M1} & & & & w_{MN} \end{bmatrix}$$

$$V = \begin{bmatrix} v_1 & v_2 & v_3 & \dots & v_M \end{bmatrix}$$

Neka su:

$$O_k = f(WX_k) \quad (3.13)$$

izlazi iz skrivenog sloja, dok je:

$$o_k = f(VO_k) = f(Vf(WX_k)) \quad (3.14)$$

izlaz iz izlaznog sloja, to jest izlaz iz neuralne mreže.

Kvadratna greška neuralne mreže je:

$$E_k = \frac{1}{2}(d_k - o_k)^2, \quad (3.15)$$

pa je:

$$V_{k+1} = V_k - \mu \frac{\partial E_k}{\partial V} \quad (3.16)$$

$$\frac{\partial E_k}{\partial V} = \frac{\partial}{\partial V} \left(\frac{1}{2}(d_k - f(VO_k))^2 \right). \quad (3.17)$$

Koristeći formule (3.10), (3.16) i (3.17) dobijamo:

$$V_{k+1} = V_k + \mu(d_k - o_k)o_k(1 - o_k)O_k^T. \quad (3.18)$$

Formula (3.18) predstavlja način dobijanja koeficijenata izlaznog sloja.

Koeficijenti neurona u skrivenom sloju se dobijaju na identičan način:

$$W_{k+1} = W_k - \mu \frac{\partial E_k}{\partial W}, \quad (3.19)$$

pri čemu je:

$$E_k = \frac{1}{2}(d_k - o_k)^2 = \frac{1}{2}(d_k - f(VO_k))^2 = \frac{1}{2}(d_k - f(Vf(WX_k)))^2. \quad (3.20)$$

Na osnovu formula (3.10), (3.19) i (3.20) dobijamo:

$$W_{k+1} = W_k + \mu(d_k - o_k)o_k(1 - o_k)V[O_k \circ (1 - O_k)]X_k^T. \quad (3.21)$$

Formula (3.21) predstavlja koeficijente poslednjeg skrivenog sloja neuralne mreže, gdje \circ predstavlja množenje vektora element po element.

Na identičan način se dobijaju i koeficijenti ako mreža sadrži više skrivenih slojeva, to jest odredi se greška na izlazu mreže, modifikuju koeficijenti izlaznog sloja, a zatim se modifikuju koeficijenti slojeva ispod. Dakle, izlazna greška se inverznim putem vraća ka ulazu mreže i vrši se korekcija koeficijenata na osnovu izlazne greške.

U nastavku slijedi pseudokod za treniranje mreže sa učenjem unazad:

Algoritam 2 Treniranje mreže sa učenjem unazad

```

1: Inicijalizacija mreže
2: for epoha do
3:   for trening podaci do
4:     for kretanje po svim nivoima do
5:       for kretanje po neuronima do
6:         Računanje izlaza funkcije mreže
7:         Računanje izlaza aktivacione funkcije - izlaz neurona
8:         Računanje greške na izlazu mreže
9:         for kretanje po neuronima izlaznog nivoa do
10:          Računanje greške na izlazu neurona
11:          Modifikacija koeficijanata neurona
12:          for kretanje po skrivenim nivoima do
13:            for kretanje po neuronima do
14:              Računanje greške na izlazu neurona
15:              Modifikacija koeficijanata neurona

```

U ovom radu za detekciju krvnih sudova mrežnjače očnog dna korišćena je mreža sa jednim skrivenim slojem.

Glava 4

Predloženi sistemi za segmentaciju krvnih sudova mrežnjače očnog dna

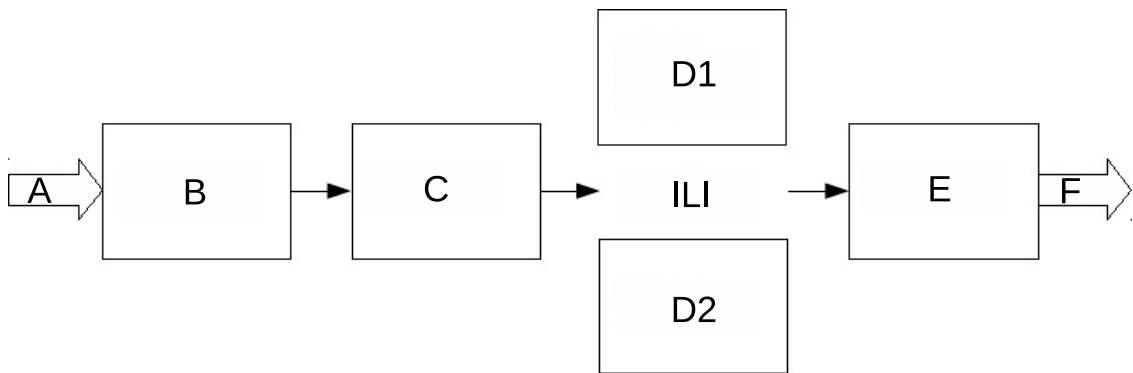
U ovom poglavlju biće dat detaljan opis predloženih sistema za segmentaciju krvnih sudova mrežnjače očnog dna. Predloženi sistemi se mogu podijeliti na sledeće korake, Slika 4.1.:

1. RGB slika (A) - ulaz sistema.
2. Početna obrada slike (B).
3. Računanje karakteristika (C).
4. Primjena jedne od metoda vještačke inteligencije (algoritma kolonije mrava (D1) ili neuralne mreže (D2)).
5. Završna obrada slike (E).
6. Rezultujuća slika (F) - izlaz sistema.

Prije nego što krenemo dalje, reći ćemo nešto o digitalnoj obradi slike primjenom morfoloških operatora koji su korišćeni u početnoj obradi slike.

4.1 Morfološki operatori

Morfologija je disciplina koja se bavi proučavanjem oblika i struktura. Pomenuta disciplina pronašla je svoju primjenu i u biologiji gdje se proučavaju oblici i struktura biljnih



Slika 4.1: Blok šema predloženih sistema.

i životinjskih organizama. Sa druge strane, digitalna morfologija je zasnovana na teoriji skupova i omogućava opis i analizu oblika digitalnih objekata. U našem slučaju, digitalna morfologija se primjenjuje kao jedan od početnih koraka u kompjuterskoj dijagnostici, to jest prilikom segmentacije krvnih sudova mrežnjače očnog dna iz digitalnih slika primjenom metoda vještačke inteligencije, kao jedan od uvodnih koraka jeste primjena digitalne morfologije na pomenutim medicinskim slikama. Kod digitalne morfologije, slika je skup elemenata (pixela) koji grupisani u dvodimenzionalnu strukturu daju određene oblike. Matematičke operacije nad skupovima se koriste za analizu oblika, prebrojavanje, prepoznavanje i slično.

Osnovne morfološke operacije se izvršavaju pojedinačno nad pikselima slike [31]. Ulazni podaci su slika, na koju se primjenjuje operator, i strukturni element, dok je izlaz slika istih dimenzija kao originalna slika, to jest ulazna slika.

Dvije osnovne morfološke operacije su:

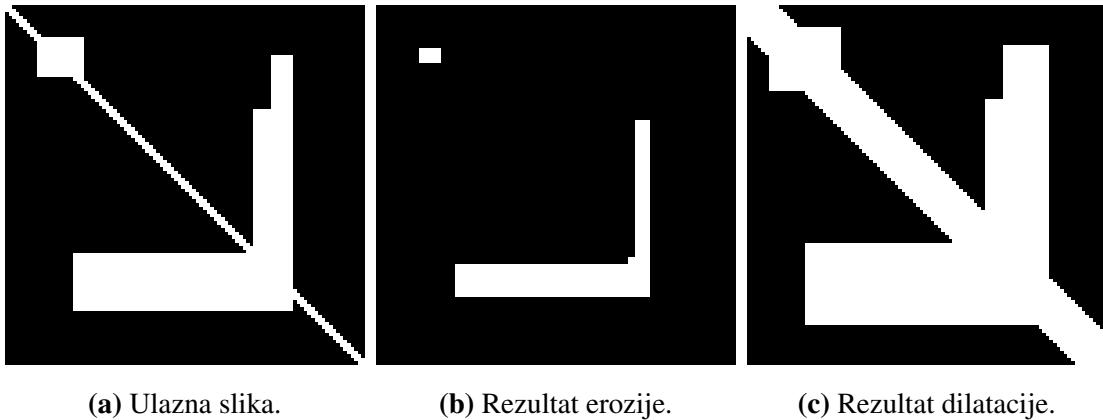
1. Erozije.

2. Dilatacije.

Kao što je već rečeno, osnovne operacije se izvršavaju pojedinačno nad pikselima slike. Vrijednost posmatranog piksela se računa na osnovu vrijednosti susjednih piksela, a susjedne piksele određuju strukturni element.

U slučaju erozije vrijednost posmatranog piksela je minimalna vrijednost od susjednih piksela, dok je u slučaju dilatacije vrijednost posmatranog piksela maksimalna vrijednost od susjednih piksela.

Na primjeru binarne slike primjenom operacije erozije dovoljno je da jedan piksel u struktornom elementu ima vrijednost nula pa da centralni piksel, to jest posmatrani piksel dobije vrijednost nula. Na ovaj način operacija erozije izaziva skupljanje. Suprotno od operacije erozije, operacija dilatacije izaziva širenje, odnosno ako bi na binarnu sliku primjenili operaciju dilatacije vrijednost posmatranog piksela bi uzela vrijednost jedinice ako bar jedan susjedni piksel ima vrijednost jedan.



Slika 4.2: Morfološke operacije nad ulaznom slikom sa kvadratom širine 8 piksela kao struktturnim elementom.

Dvije izvedene morfološke operacije, koje se dobijaju kombinacijom osnovnih morfoloških operacija su: morfološko otvaranje i morfološko zatvaranje slike.

Kod operacije morfološkog otvaranja prvo se vrši erozija, a zatim dilatacije sa istim struktornim elementom. Sa morfološkim otvaranjem slike vrši se odstranjivanje šuma vrijednosti 1 i zaobljavanje ivica u slučaju binarne slike. Otvaranje slike A sa sarukturnim elementom B je dato formulom:

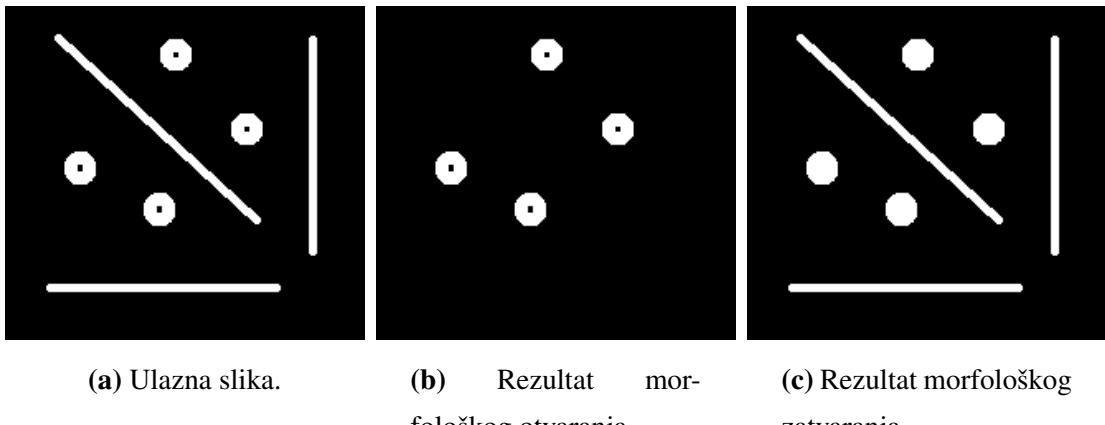
$$A \circ B = (A \ominus B) \oplus B, \quad (4.1)$$

gdje je \ominus operacija erozije, a \oplus operacija dilatacije.

Morfološko zatvaranje slike struktornim elementom predstavlja dilataciju, a zatim eroziju sa istim struktornim elementom. Na ovaj način vrši se odstranjivanje šuma vrijednosti 0, to jest uklanjanje rupa u struktornom elementu koji se sastoji od piksela sa vrijednošću 1. Zatvaranje slike A sa sarukturnim elementom B je dato formulom:

$$A \bullet B = (A \oplus B) \ominus B. \quad (4.2)$$

Na Slici 4.3. je prikazan rezultat morfološkog otvaranja i zatvaranja iste ulazne slike



Slika 4.3: Izvedene morfološke operacije nad ulaznom slikom sa diskom poluprečnika 4 piksela kao strukturnim elementom.

kako bi se konkretno na primjeru pokazala razlika između ove dvije izvedene morfološke operacije. Ulazna slika sadrži linije čija je debljina manja od 8 piksela, kao i diskove čiji je prečnik veći od 8 piksela. Unutrašnji diskovi su prečnika manjeg od 8 piksela. Kao strukturni element je korišćen disk poluprečnika 4 piksela.

Morfološkim otvaranjem vršimo odstranjivanje elemenata čija je vrijednost 1, a koji su manji od strukturnog elemenata, to jest odstranjuju se elementi koji se mogu sadržati u struktornom elementu, a čija je vrijednost 1. Na ovaj način smo odstranili linije.

Prilikom morfološkog zatvaranja ulazne slike odstranili smo elemente čija je vrijednost 0, a koji su manji od strukturnog elementa, to jest struktorni element može da ih sadrži, a njihova je vrijednost 0. Na ovaj način smo odstranili unutrašnje diskove.

4.2 Početna obrada slike

Slika 4.4a. predstavlja RGB sliku krvnih sudova mrežnjače očnog dna. RGB model boja se sastoji od tri kanala: crvenog (engl. *red*), zelenog (engl. *green*) i plavog (engl. *blue*) [32]. Najbolji kontrast između krvnih sudova i pozadine daje zeleni kanal [9], Slika 4.4b. Kao prvu karakteristiku za segmentaciju krvnih sudova koristeći neuralnu mrežu je korišćen inverzni zeleni kanal (karakteristika 1), Slika 4.5a.

Prilikom početne obrade slike, to jest pripreme slike za dalju obradu, vrši se morfološko otvaranje inverznog zelenog kanala kako bi se odstranio prvenstveno optički disk, a samim tim i smanjio uticaj pozadine.



(a) Mrežnjača očnog dna.

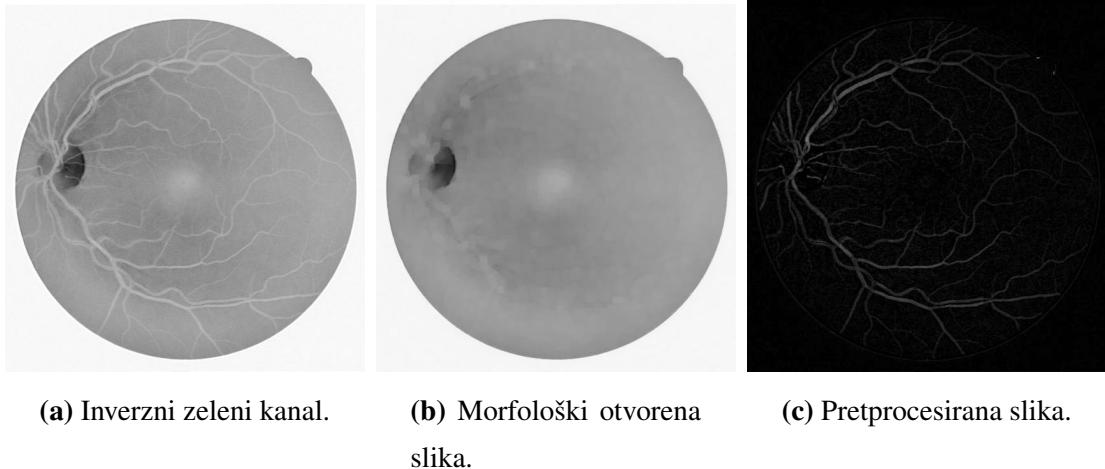
(b) Zeleni kanal.

Slika 4.4: Testna slika DRIVE baze.

U našem slučaju vršeno je morfološko otvaranje inverznog zelenog kanala, Slike 4.5a., sa strukturnim elementom koji sadrži krvni sud, odnosno krvni sudovi su posmatrani kao šum. Da bi to postigli, potrebno je da je širina strukturnog elementa veće od prosječne širine krvnog suda. Na ovaj način smo dobili novu sliku koja se sastoji samo od pozadine, Slika 4.5b.

Slika koja je dobijena morfološkim otvaranjem, koja u stvari predstavlja pozadinu sa optičkim diskom, se oduzima od originalnog inverznog zelenog kanala i na taj način se odstranjuje pozadina i optički disk. Na Slici 4.5c. je prikazana dobijena slika nakon oduzimanja.

Morfološko otvaranje je vršeno sa kvadratom 9 piksela kao strukturnim elementom, koji je dobio eksperimentalnim putem na trening slikama DRIVE baze kao optimalni element. Eksperiment je sproveden tako što je računata tačnost algoritma kolonije mrava za različite veličine strukturnog elementa. Očekivana vrijednost strukturnog elementa takođe je bila 9 piksela, jer je prosječna širina krvnog suda u DRIVE bazi 8 piksela [5]. Shodno tome, za druge baze slika, to jest za slike sa kamere različite rezolucije, strukturni element je računat srazmjerno odnosu broja piksela unutar FOV-a DRIVE baze i posmatrane baze. Na taj način strukturni element koji je korišćen za STARE bazu je 12 piksela.



(a) Inverzni zeleni kanal. (b) Morfološki otvorena slika. (c) Preprocesirana slika.

Slika 4.5: Početna obrada slike.

4.3 Računanje karakteristika

Pored inverznog zelenog kanala (karakteristika 1) u ovom radu su korišćene i dvije linijske karakteristike koje se računaju iz preprocesirane slike:

1. Linijski detektor [5] (karakteristika 2).
2. Linijski detektor sa ortogonalnom linijom [5] (karakteristika 3).

4.3.1 Linijski detektor

Linijski detektor (karakteristika 2) nam govori kolika je vjerovatnoća da posmatrani piksel slike pripada nekoj liniji na slici. U našem slučaju, tražimo linije u preprocesiranoj slici, Slika 4.7a., koje predstavljaju krvne sudove.

Pomenuti detektor se primjenjuje na sledeći način: kroz sliku se kreće piksel po piksle, to jest linijski detektor se računa pojedinačno za svaki piksel slike. Oko posmatranog piksela se uzima maska 15×15 piksela. Veličina maske 15×15 je uzeta na osnovu širine krvnih sudova sa ciljem da se dobije što bolji kontrast između krvnih sudova i pozadine [5]. Centralni piksel (i, j) maske predstavlja posmatrani piksel. Zatim se u uzetoj masci vrši rotiranje linije debljine jedan piksel pod uglom od 15° ($0^\circ, 15^\circ, 30^\circ, 45^\circ \dots 150^\circ, 165^\circ$) oko centralnog piksela, Slika 4.6a. Nakon računanja 12 linija, za svih 12 uglova, uzima se linija sa najvećom srednjom vrijednosti ($L(i, j)$), Slika 4.6b. Razlika između linije sa

najvećom srednjom vrijednosti i srednje vrijednosti maske ($N(i, j)$) predstavlja vrijednost piksela druge karakteristike ($S(i, j)$), formula (4.3).

$$S(i, j) = L(i, j) - N(i, j) \quad (4.3)$$

Na Slici 4.7b. je prikazan rezultat linijskog detektora Slike 4.7a.

Dva problema koji se javljaju kod linijskog detektora su:

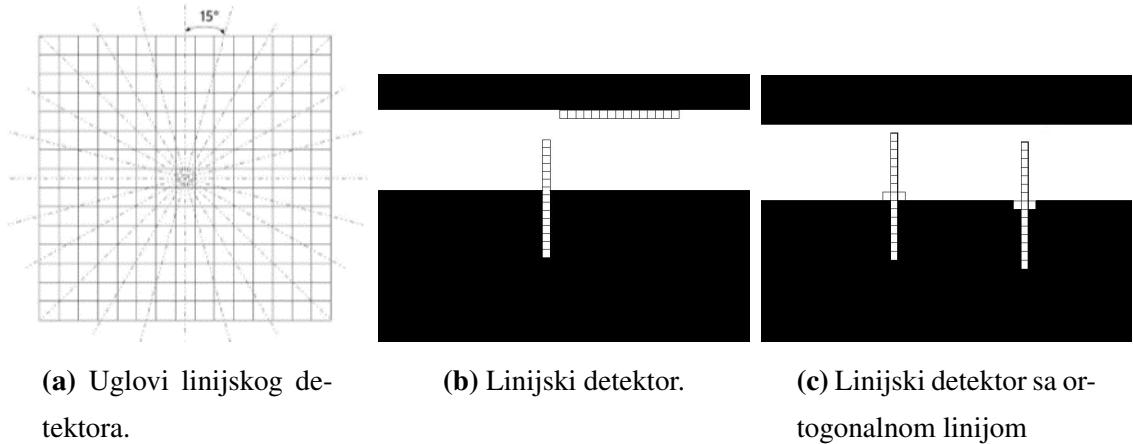
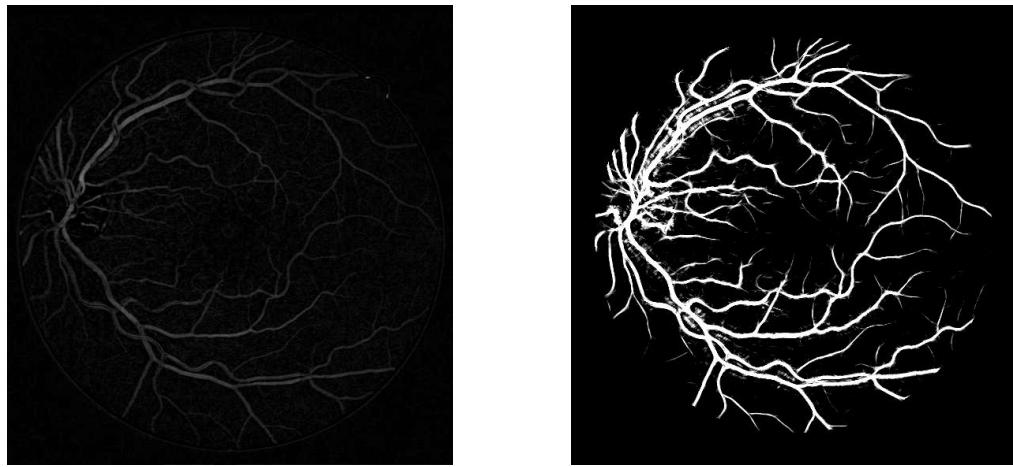
1. Greška na graničnim pikselima između krvnih sudova i pozadine.
2. Greška kada se linijski detektor primjeni po okviru FOV-a, odnosno kada maska 15×15 uzima centralni piksel na granicama FOV-a i samim tim obuhvati i piksele van FOV-a.

Prvi problem, greška kod graničnih piksela krvnih sudova i pozadine, je nastao zbog same prirode linijskog detektora. Pomenuti detektor traži liniju sa najvećom srednjom vrijednosti, pa iako je centralni piksel pozadinski, a maska obuhvata piksele krvnih sudova, i linija će obuhvatiti piksele krvnih sudova i na taj način će centralni (pozadinski) piksel dobiti neku vrijednost krvnog suda. Ovaj problem riješen je primjenom linijskog detektora sa ortogonalnom linijom, Slika 4.6c.

Drugi problem, greška koja se javlja po okviru FOV-a je izbjegнута на sledeći начин: kada se linijski detektor primjeni na ivicama FOV-a, odnosno kada maska 15×15 obuhvati i dio piksela koji su van FOV-a, njihova vrijednost se mijenja sa srednjom vrijednosti piksela koji su unutar FOV-a i obuhvaćeni su maskom. Na ovaj način se izbjeglo da linijski detektor piksele po okviru FOV-a predstavi krvnim sudovima.

4.3.2 Linijski detektor sa ortogonalnom linijom

Glavni cilj linijskog detektora sa ortogonalnom linijom (karakteristika 3), Slika 4.8b., jeste da napravi jasnu granicu između graničnih piksela, to jest piksela koji su na ivici između krvnih sudova i pozadine. To se postiže na sledeći način: identično kao kod linijskog detektora, tražimo liniju sa najvećom srednjom vrijednošću ($L(i, j)$) unutar maske 15×15 uzete unutar FOV-a preprocesirane slike. Zatim se u odnosu na njen centralni piksel uzima ortogonalna linija dužine tri piksela. Vrijednost piksela u slici koja predstavlja

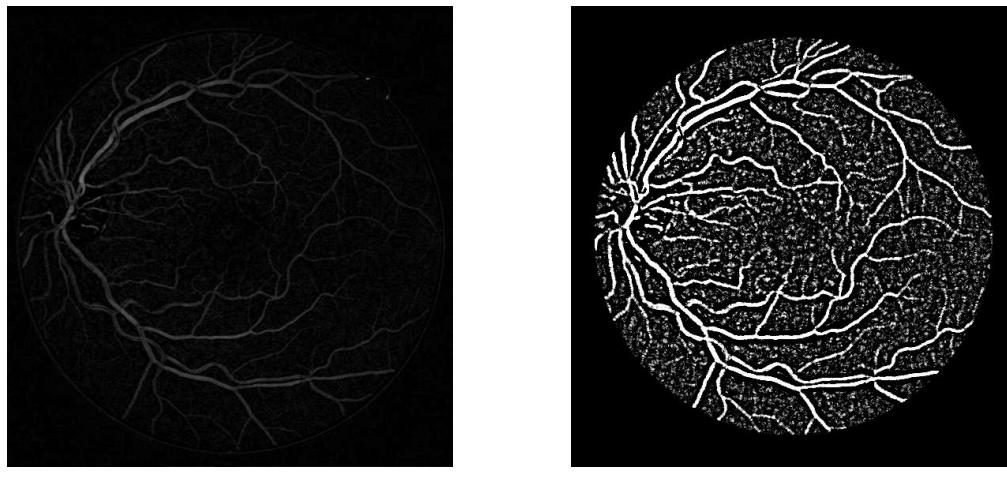
**Slika 4.6:** Način računanja linijskih karakteristika.**Slika 4.7:** Linijska karakteristika.

treću karakteristiku ($S_0(i, j)$) je srednja vrijednost ortogonalne linije ($L_0(i, j)$) umanjene za srednju vrijednost maske ($N(i, j)$), formula (4.4).

$$S_0(i, j) = L_0(i, j) - N(i, j) \quad (4.4)$$

Nedostatak treće karakteristike jeste zbog velike količine šuma koju unosi u regionima gdje maska nije obuhvatila krvni sud, jer je u tim slučajevima srednja vrijednost maske mala.

Nakon dobijanja sve tri karakteristike koje se koriste za detekciju krvnih sudova mrežnjače očnog dna vrši se normalizacija karakteristika kako bi metode u manjem broju it-



(a) Preprocesirana slika.

(b) Linijski detektor sa ortogonalnom linijom.

Slika 4.8: Linijska karakteristika.

eracija konvergirale. Normalizacija se vrši po sledećoj formuli:

$$y_i = \frac{x_i - \mu_i}{\sigma_i},$$

gdje je x_i i -ta karakteristikta ($i=1,2,3$), dok su μ_i i σ_i srednja vrijednost i standardna devijacija i -te karakteristike [5]. Na ovaj način smo i smanjili uticaj osvjetljaja između slika. U nastavku je predstavljen pseudokod za računanje linijskih karakteristika, Algoritam 3.

4.4 Primjena metoda vještačke inteligencije u predloženim sistemima

U ovom radu je izvršena primjena dvije metode vještačke inteligencije za segmentaciju krvnih sudova mrežnjače oka:

1. Algoritam kolonije mrava.
2. Neuralne mreže.

Kod prve metode, algoritma kolonije mrava, linijske karakteristike se koriste za određivanje funkcija feromona i heuristike, dok se kod metode neuralne mreže kao ulaz koriste sve tri navedene karakteristike.

Algoritam 3 Karakteristike za detekciju krvnih sudova

```

1: function KARAKTERISTIKE(slika, maska)
2:   zeleniKanal  $\leftarrow$  zeleni kanal slike slika
3:   invZeleniKanal  $\leftarrow$  inverzni zeleniKanal tj. karakteristika 1
4:   MOinvZeleniKanal  $\leftarrow$  morfološki otvaren invZeleniKanal
5:   noviInvZeleniKanal  $\leftarrow$  invZeleniKanal - MOinvZeleniKanal
6:   uglovi  $\leftarrow$  niz od 12 uglova ( $0^\circ, 15^\circ, 30^\circ, 45^\circ \dots 150^\circ, 165^\circ$ )
7:   for uglovi do
        matrica koja sadrži informacije o pozicije piksela lin-
8:     ugloviPozicija  $\leftarrow$  ije debljine jedan piksel za dati ugao u odnosu na cen-
        tralni piksel matrice veličine  $15 \times 15$ 
9:   m  $\leftarrow$  broj kolona slike invZeleniKanal
10:  n  $\leftarrow$  broj vrsta slike invZeleniKanal
11:  for m do
12:    for n do
13:      frame  $\leftarrow$  kretanje kroz noviInvZeleniKanal sa maskom  $15 \times 15$ 
14:      if frame sadrži okvir FOV-a then
        Zamjena piksela koji su van FOV-a sa srednjom vrijednošću un-
15:        utrašnjih piksela
16:      for uzimanje pozicija ugloviPozicija za uglove do
17:        Traženje maksimalne srednje vrijednosti linije u frame
18:        karakteristika2  $\leftarrow$  smještanje maksimuma tj. karakteristike 2
19:        karakteristika3  $\leftarrow$ 
            srednja vrijednost linije ortogonalne na maksimalnu liniju
            tj. dobijanje karakteristike 3
20:      Umanjenje karakteristika2 i karakteristika3 za srednju vrijednost frame
21:  Normalizacije sve tri karakteristike

```

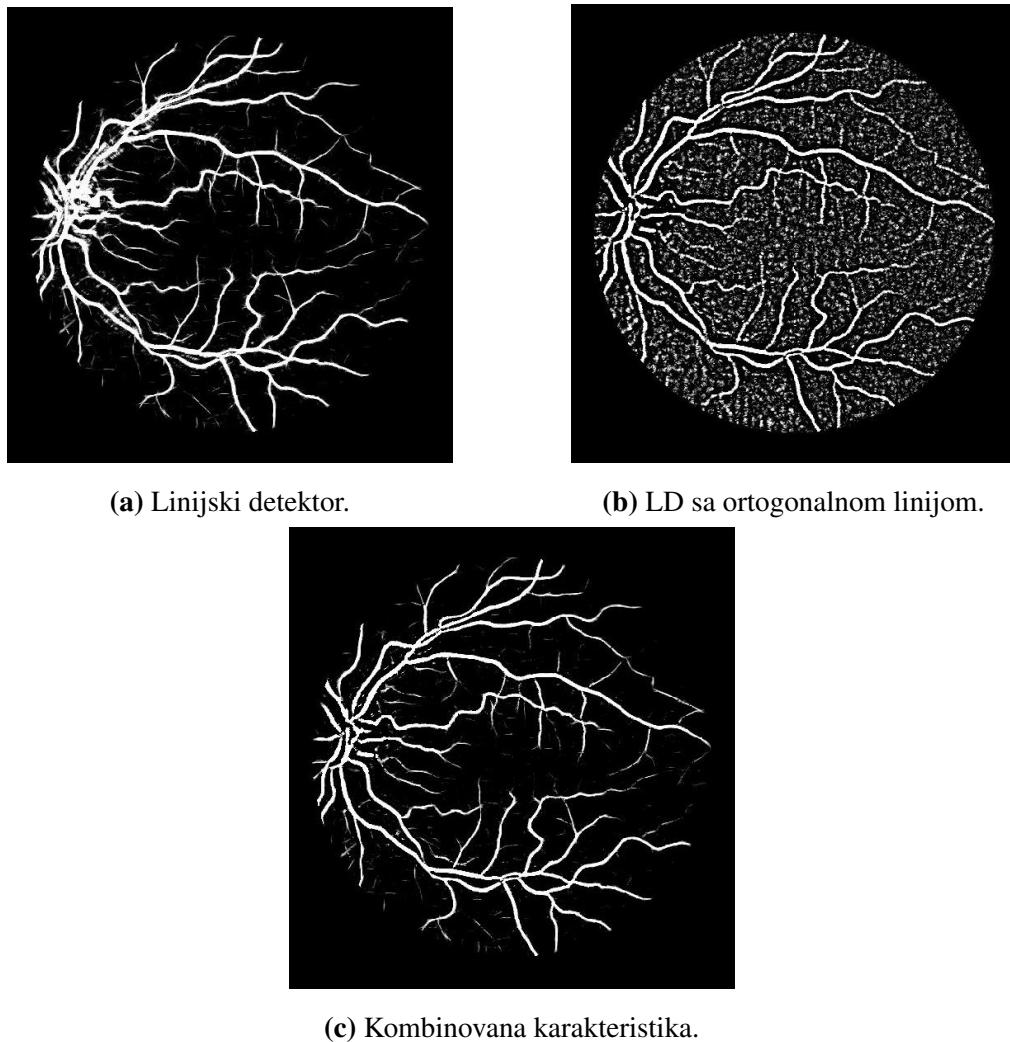
4.4.1 Algoritam kolonije mrava

Za dobijanje funkcija feromona i heuristike korišćene su dvije linijske karakteristikе. Linijski detektor vrši detekciju linija na slici, odnosno u našem slučaju krvnih sudova na pretprocesiranoj slici, uz problem detekcije piksela na granici krvni sud-pozadina. Da bi riješili problem graničnih piksela, izvršena je kombinacija linijskog detektora i linijskog detektora sa ortogonalnom linijom čija je glavna uloga da odredi jasnu granicu

između pomenutih graničnih piksela. Na Slici 4.9. su prikazane linijske karakteristike kao i kombinovana karakteristika koja je korišćena kao ulaz algoritma kolonije mrava. Kombinovana karakteristika je dobijena na sledeći način:

$$f_c = \begin{cases} f_1 & \text{ako } f_2 > 0, \\ 0 & \text{ako } \text{ostalo}. \end{cases} \quad (4.5)$$

gdje f_c predstavlja kombinovanu karakteristiku, dok f_1 i f_2 predstavljaju linijski detektor i linijski detektor sa ortogonalnom linijom, respektivno.



Slika 4.9: Karakteristike algoritma kolonije mrava.

Nakon računanja kombinovane karakteristike krećemo sa inicijalizacijom populacije mrava. Veličina populacije mrava koja se postavlja unutar FOV-a iznosi 70% od ukupnog broja piksela FOV-a. U ovom slučaju, kako bi favorizovali krvne sudove, mrave ne

postavljamo u slučajno odabrane piksele već u 70% piksela maksimalne vrijednosti kombinovane karakteristike.

U svakoj iteraciji, mrav donosi odluku o svojoj sledećoj akciji, to jest vrši odabir piksela u koji će da pređe i polaze feromon. Količina feromona koju mrav polaže je jednaka vrijednosti posmatranog piksela u kombinovanoj karakteristici uvećana za konstantni dio C_{add} [24]. Vrijednost konstante C_{add} u našem slučaju iznosi 0.2. Konstantni dio C_{add} je postavljen na samom startu i nije se mijenjao, već se tražena optimalna vrijednost isparenja feromona.

Prilikom kretanja mrava razlikujemo dva slučaja:

1. U jednom pikselu se može nalaziti samo jedan mrav.
2. Više mrava može da dijeli jedan piksel.

U prvom slučaju, mrav ne može da se kreće ako je okružen ostalim mravima, odnosno može da bira samo piksele koji su slobodni. Suprotno od toga, u drugom slučaju, mrav bez obzira na položaj ostalih mrava vrši odabir narednog piksela. Prilikom rešavanja našeg problema korišćen je prvi slučaj.

Mrav vrši odabir jednog od okolnih piksela u koji prelazi na osnovu količine feromona u posmatranom pikselu i heuristike do posmatranog piksela. Količina feromona σ koja se nalazi u pikselu jednaka je sumi položenog feromona u pikselu umanjenoj za ispranje feromona na kraju svake iteracije. Heuristika do posmatranog piksela je vrijednost posmatranog piksela u kombinovanoj karakteristici. U slučaju kad ni jedan od okolnih piksela ne sadrži feromon, odluka o prelasku se donosi samo na osnovu heuristike. Na kraju, da bi izbjegli upadanje mrava u lokalni minimum nije dozvoljeno vraćanje u prethodni piksel.

Prilikom inicijalizacije populacije svi mravi imaju istu količinu energije koja se smanjuje prilikom kretanja. Na ovaj način stičemo kontrolu nad trenutnom veličinom populacije i favorizujemo mrave koji se kreću po optimalnim putanjama. Način smanjenja energije mrava dat je formulom (4.6).

$$E_{new} = E_{old} - E_{dec} = E_{old} - \frac{1}{\sigma}, \quad (4.6)$$

gdje E_{new} predstavlja novu količinu energije, dok E_{old} predstavlja količinu energije koju je posjedovao mrav prije poslednje akcije, a σ količinu feromona u pikselu u koji je mrav prešao.

Na kraju svake iteracije dolazi do isparenja feromona, odnosno ukupna količina feromona σ u svakom pikselu se smanjuje za konstantnu količinu feromona C_{evap} . Optimalna količina isparenje feromona iznosi 0.28 i određena je eksperimentalnim putem.

U Tabeli 4.1. je prikazana srednja vrijednost tačnosti trening slika DRIVE baze za različite količine ispravanja feromona na osnovu koje je i donešena odluka o optimalnoj količini isparenja.

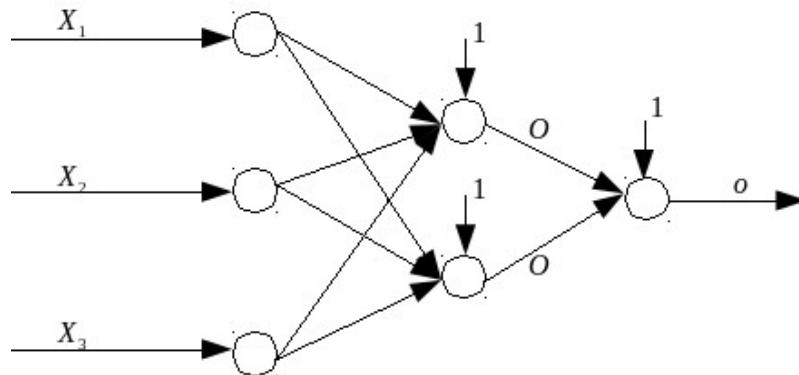
Tabela 4.1: Srednja vrijednost tačnosti trening slika DRIVE baze.

Količina isparenja	Tačnost [%]
0.1	93.1999
0.12	93.3365
0.14	93.4535
0.16	93.5166
0.18	93.5948
0.2	93.6233
0.22	93.6561
0.24	93.6904
0.26	93.6917
0.28	93.7051
0.3	93.7041
0.32	93.6975
0.34	93.6937
0.36	93.6783
0.38	93.6671
0.4	93.6519
0.42	93.6436
0.44	93.6102
0.46	93.5995
0.48	93.5786
0.5	93.5459

4.4.2 Neuralna mreža

Struktura neuralne mreže koja je korišćena za rešavanje ovog problema je prikazana na Slici 4.10. Mreža se sastoji od tri sloja:

1. Ulazni sloj - ulazni sloj ne vrši obradu podataka već samo prosleđuje podatke sa ulaza na izlaz prema neuronima u prvom skrivenom sloju. S obzirom da imamo tri ulazne karakteristike, broj neurona u ulaznom sloju je tri.
2. Skriveni sloj - skriveni sloj se sastoji od dva neurona. Sa većim brojem neurona u ovom sloju bi samo usložili sistem, a ne bi dobili bolje performanse. Razloga zbog kojeg je to tako jestе što nelinerani klasifikator ne daje bolje rezultate od linarnog prilikom rešavanja problema segmentacije krvnih sudova mrežnjače očnog dna primjenom navedenih karakteristika [5]. Iz tog razloga nismo imali potrebu za većim brojem skrivenih slojeva.
3. Izlazni sloj - u izlaznom sloju se nalazi jedan neuron koji nam govori da li je ulazni piksel (koji je predstavljen preko tri ulazne karakteristike) krvni sud ili pozadina. Ulazi neurona u izlaznom sloju su izlazi neurona skrivenog sloja.



Slika 4.10: Neuralna mreža korišćena za segmentaciju krvnih sudova mrežnjače očnog dna.

Kod svih neuroni u mreži linearna funkcija mreže sa nenultim bias-om je korišćena kao funkcija mreže, dok je kao aktivaciona funkcija korišćen unipolarni sigmoid.

Označimo sa W i V koeficijente neurona skrivenog i izlaznog sloja, respektivno. Tada je izlaz neuralne mreže sa Slike 4.10. u k -tom koraku:

$$o_k = f(V O_k) = f(V f(W X_k)), \quad (4.7)$$

gdje su X_k ulazne karakteristike u k-tom koraku, a O_k izlazi skrivenog sloja u k-tom koraku.

Kao što je već rečeno, da bi se minimizovala kvadratna greška, modifikacija koeficijenata neurona je vršena primjenom LMS algoritma:

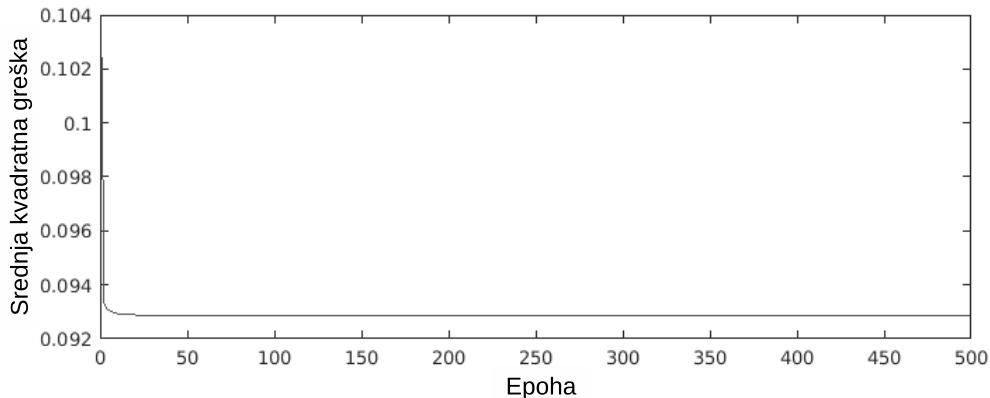
$$V_{k+1} = V_k - \mu \frac{\partial E_k}{\partial V}, \quad (4.8)$$

$$V_{k+1} = V_k - \mu (d_k - o_k) o_k (1 - o_k) O_k^T, \quad (4.9)$$

$$W_{k+1} = W_k - \mu \frac{\partial E_k}{\partial W}, \quad (4.10)$$

$$W_{k+1} = W_k - \mu (d_k - o_k) o_k (1 - o_k) V [O_k \circ (1 - O_k)] X_k^T. \quad (4.11)$$

Na Slici 4.11. je prikazana konvergencija LMS algoritma. Sistem je treniran kroz 500 epoha. Koeficijenti neurona zavisno od srednje kvadratne greške su modifikovani na kraju svake iteracije. Broj iteracija u jednoj epohi je jednak broju trening podataka. Za trening podatke je korišćeno 10000 slučajno uzetih piksela krvnih sudova i isto toliko slučajno uzetih piksela pozadine iz trening slika DRIVE baze.



Slika 4.11: Konvergencija LMS algoritma.

4.5 Završna obrada slike

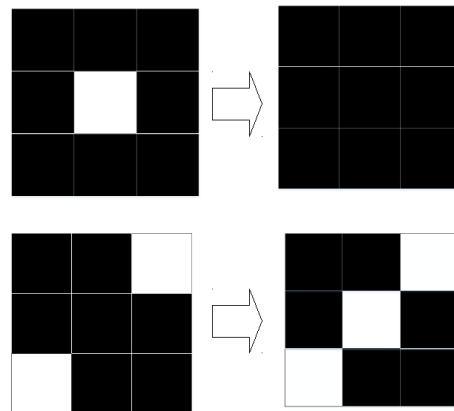
Nakon što izvršimo klasifikaciju piksela koristeći algoritam kolonije mrava ili neuralnu mrežu i dobijemo izlaznu sliku, pristupamo završnoj obradi slike. Završna obrada slike obuhvata dvije faze, Slika 4.12.:

1. Detektovanje piksela greške u krvnim sudovima.
2. Detektovanje piksela greške u pozadini.

Kod detekcije piksela greške u krvnim sudovima krećemo se sa maskom u obliku kvadrata 3×3 piksela kroz sliku. Ako je centralni piksel krvni sud, a svi njegovi okolni pikseli pozadina, onda se i centralni piksel proglašava pozadinom.

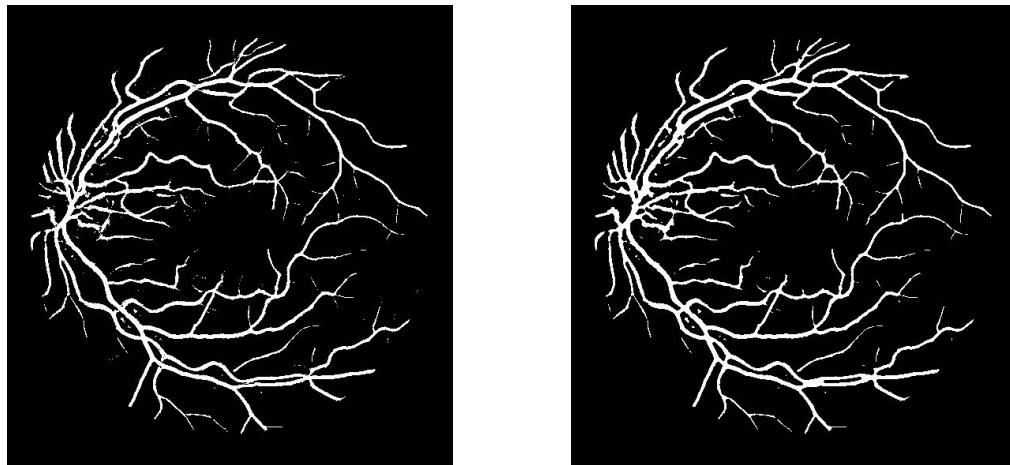
U slučaju detekcije piksela greške u pozadini, takođe se kroz sliku kreće sa maskom u obliku kvadrata 3×3 piksela i uspostavlja se linija od 3 piksela (pod uglom $0^\circ, 45^\circ, 90^\circ, 135^\circ$) u odnosu na centralni piksel. U slučaju da su druga dva piksela krvni sudovi, a centralni piksel pozadina, tada se i centrani piksel proglašava krvnim sudom.

Postupak se ponavlja sve dok postoji razlika između slike iz prethodne iteracije i novodobijene slike.



Slika 4.12: Završna obrada slike.

Na Slici 4.13. je prikazan rezultat prije i poslije završne obrade slike jedne od testnih slika DRIVE baze podataka.



(a) Rezultata bez završne obrade slike.

(b) Rezultat nakon završne obrade slike.

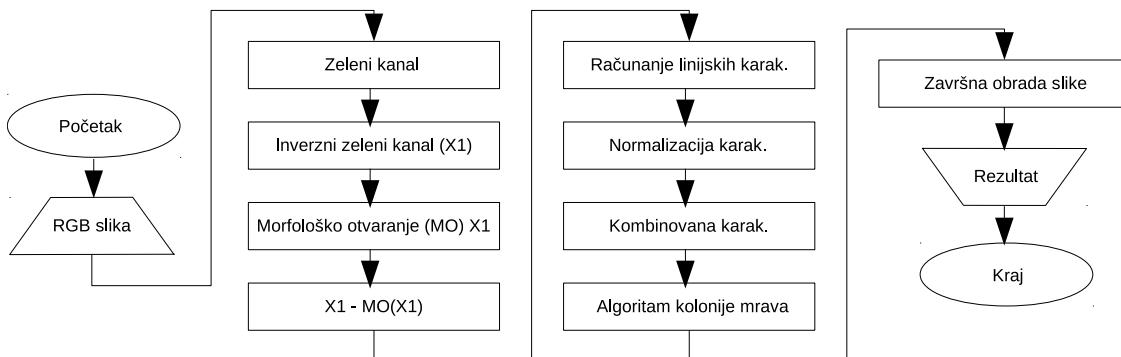
Slika 4.13: Testna slika DRIVE baze.

4.6 Struktura sistema

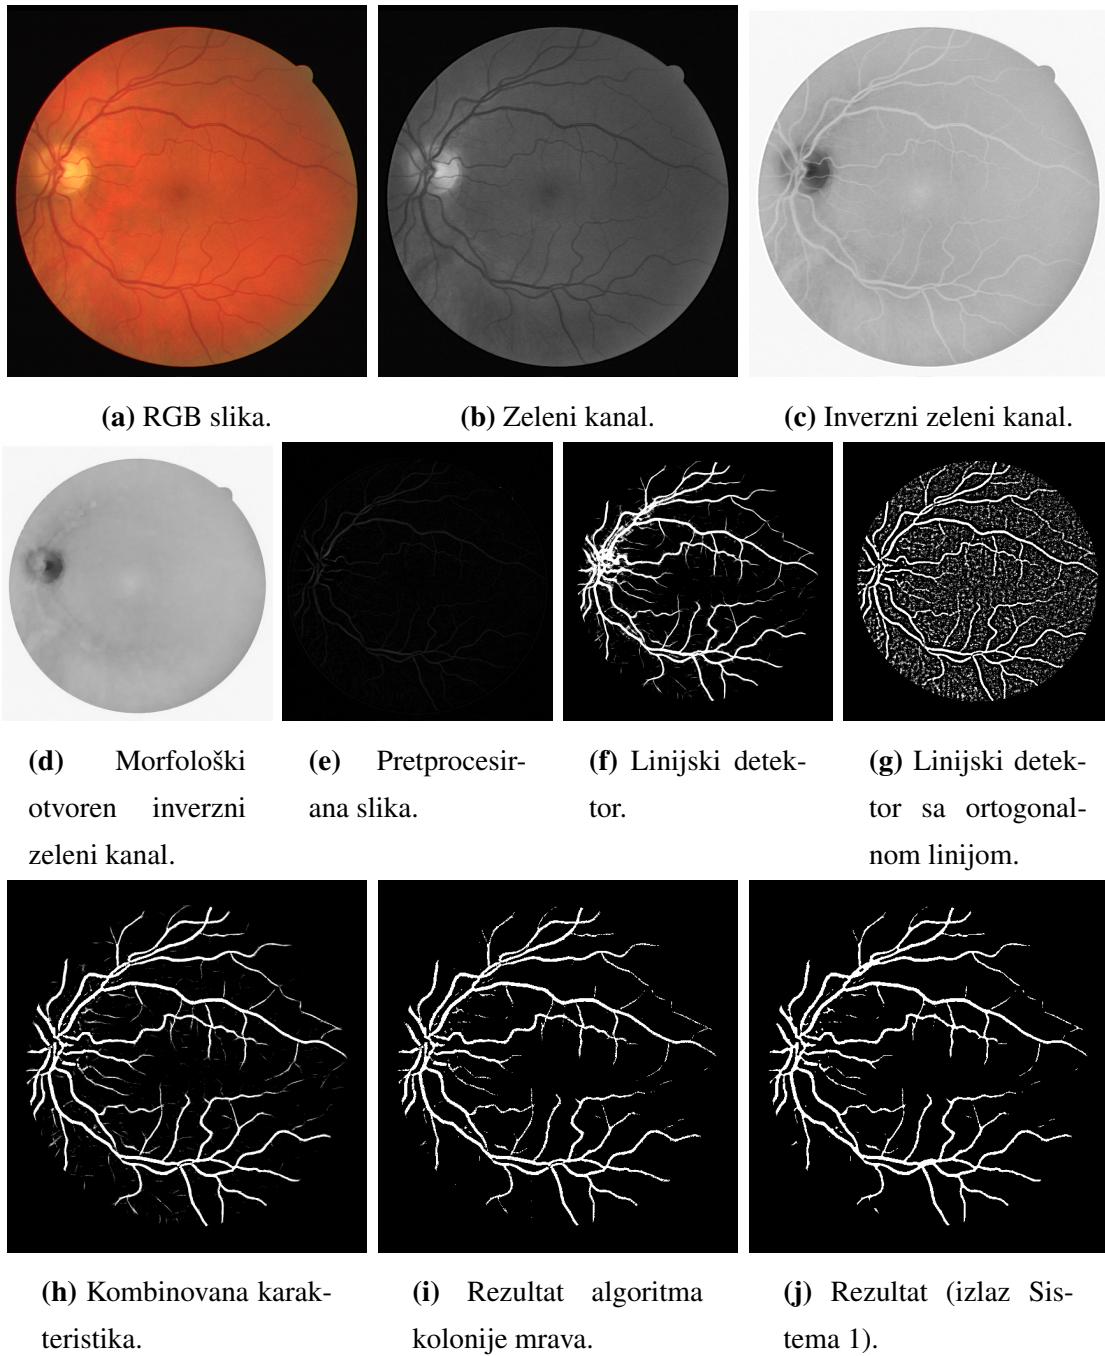
U ovom radu je izvršena segmentacija krvnih sudova mrežnjače očnog dna primjenom dvije metoda vještačke inteligencije: algoritma kolonije mrava i neuralna mreža. Prije nego što pređemo na sekciju sa rezultatima biće data detaljna struktura predloženih sistema.

4.6.1 Sistem sa algoritmom kolonije mrava

Slika 4.14. predstavlja strukturu sistema za detekciju krvnih sudova mrežnjače očnog dna primjenom algoritma kolonije mrava (Sistem 1). Ulaz sistema je RGB slika mrežnjače očnog dna iz koje se izvlači zeleni kanal i u ostatku sistema se samo on koristi. Nakon morfološkog otvaranja inverznog zelenog kanala računaju se linijske karakteristike iz pretprocesirane slike, a zatim se vrši njihova kombinacija. Završna obrada slike se primjenjuje na slici dobijenoj na izlazu algoritma kolonije mrava, koji kao za funkciju feromona i heuristike koristi kombinovanu karakteristiku. Izlazi koraka opisanog sistema su prikazani na Slici 4.15.



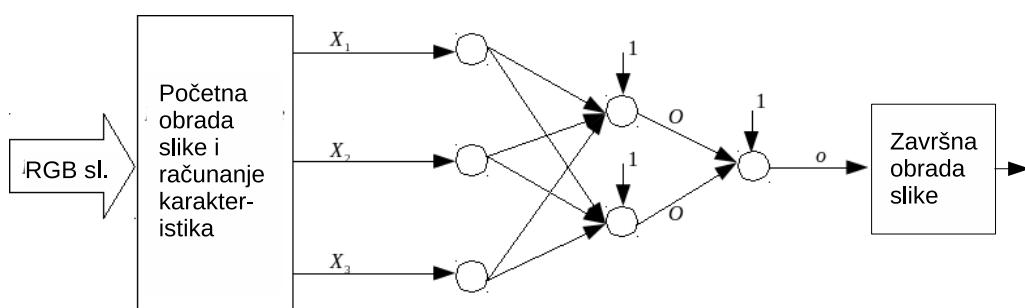
Slika 4.14: Struktura Sistema 1.



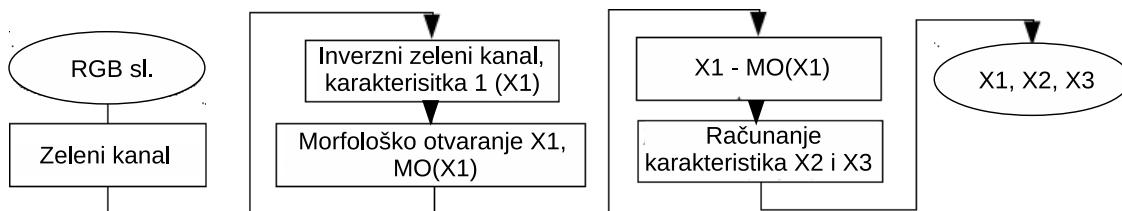
Slika 4.15: Testna slika DRIVE baze.

4.6.2 Sistem sa neuralnom mrežom

Na Slici 4.16. je prikazana struktura sistema za detekciju krvnih sudova mrežnjače očnog dna koristeći neuralnu mrežu (Sistem 2). Sa slike se vidi da je ulaz sistema RGB slika na koju se primjenjuje početna obrada (preprocesiranje slike), a zatim se računaju karakteristike. Preprocesiranje slike i računanje karakteristika je predstavljeno blok šemom na Slici 4.17. Nakon toga, neuralna mreža na osnovu ulaznih karakteristika i znanja kojeg posjeduje vrši segmentaciju krvnih sudova. Sledeći korak, to jest nakon što neuralna mreža izvrši segmentaciju krvnih sudova, jeste završna obrada slike. Na Slici 4.18. su prikazane slike na izlazima koraka opisanog sistema.



Slika 4.16: Struktura Sistema 2.



Slika 4.17: Preprocesiranje i računanje karakteristika.

U nastavku slijedi kod za treniranje i testiranje neuralne mreže za detekciju krvnih sudova mrežnjače očnog dna.

Treniranje sistema:

- 1 **load(' karakteristike .mat');**
- 2 **load('d.mat');**
- 3 **mi = 0.25;**
- 4 **greska = [];**
- 5 **v = rand(1,3);**
- 6 **w = rand(2,4);**
- 7 **for iter = 1:15**

```

8 greskaIter = [];
9 for k = 1:length( karakteristike )
10     X = karakteristike (:, k);
11     u = w*X;
12     O = 1./(1+exp(-1*(u)));
13     O = [O;1];
14     u = v*O;
15     o = 1/(1+exp(-(u)));
16     delta = (d(k)-o)*o*(1-o);
17     e = d(k)-o;
18     greskaIter = [ greskaIter e^2];
19     v = v + mi*delta*O';
20     w1 = w(1,:) + mi*delta*v*(O.)*(1-O))*X';
21     w2 = w(2,:) + mi*delta*v*(O.)*(1-O))*X';
22     w = [w1;w2];
23 end
24 greska = [greska sum(greskaIter)/length( greskaIter )];
25 end
26 save(' koeficijentiMreze .mat', 'w', 'v')
27 figure, plot(greska)

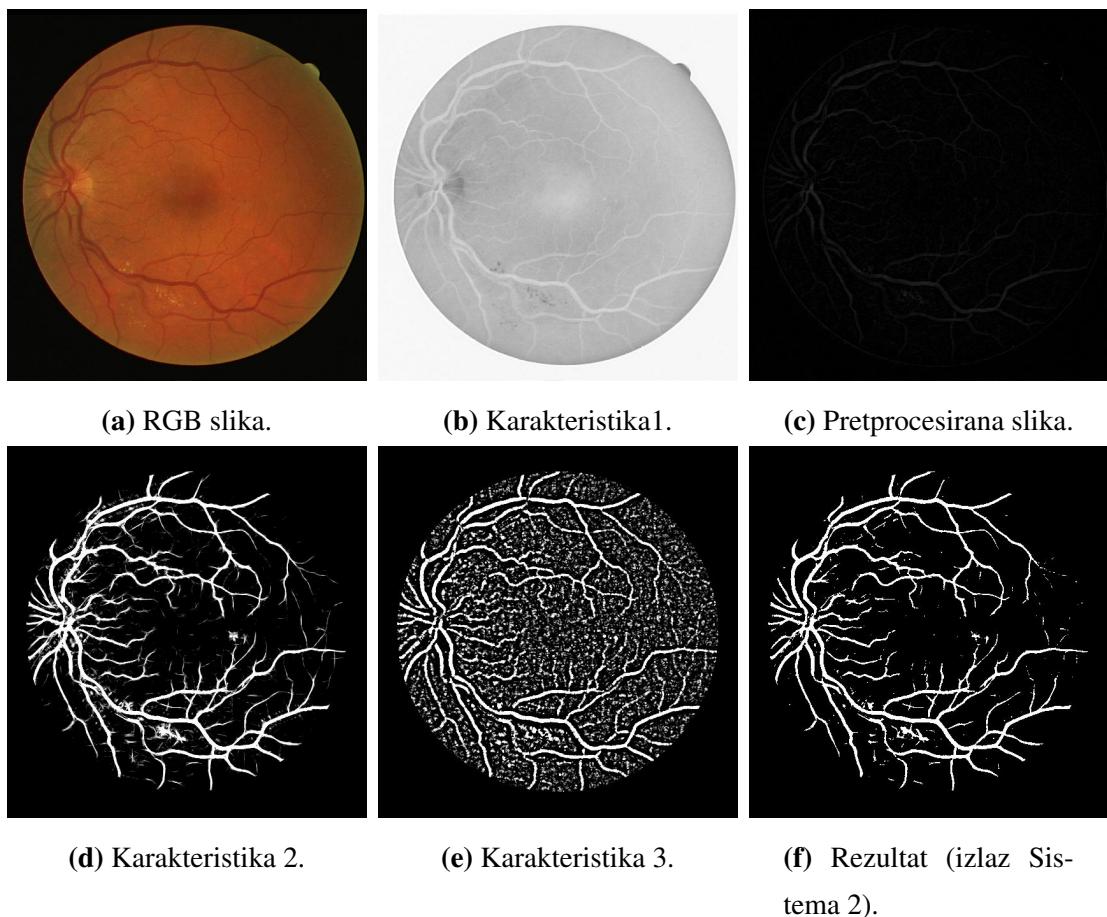
```

Testiranje sistema:

```

1 load(' koeficijentiMreze .mat');%koef
2 o = zeros(m,n);
3 for k = 1:length( karakteristike )
4     X = karakteristike (:, k);
5     O = 1./(1+exp(-(w*X)));
6     O = [O;1];
7     u = v*O;
8     o(k) = 1/(1+exp(-(u)));
9 end

```



Slika 4.18: Slike na izlazima Sistema 2.

Glava 5

Rezultati

Metrike koje su korišćene za testiranje validnosti sistema su:

1. Tačnost (engl. *accuracy*).
2. F_1 ocjena (engl. *F_1 score*).
3. Lokalna tačnost (engl. *local accuracy*) [8].

Tačnost predstavlja odnos tačno klasifikovanih podataka i ukupnog broja podataka za klasifikaciju. U našem slučaju je to odnos tačno klasifikovanih piksela krvnih sudova i pozadinskih piksela unutar FOV-a i ukupnog broja piksela u FOV-u. S obzirom da je broj piksela krvnih sudova znatno manji od broja piksela pozadine, može se zaključiti da tačnost i nije dobar pokazatelj validnosti sistema. Iz tog razloga su uvedene druge dvije metrike. Da bi se izračunala F_1 ocjena, potrebno je prvo uvesti pojmove *precision* i *recall*.

		Predviđena klasa	
		1	0
Prava klasa	1	True Positive (TP)	False Negative (FN)
	0	False Positive (FP)	True Negative (TN)

Slika 5.1: Svi mogući izlazi klasifikatora.

Precision predstavlja odnos tačno klasifikovanih podataka prve klase (u našem slučaju piksela krvnih sudova) i svih podataka koji su klasifikovani kao prva klasa, Formula 5.1,

dok *recall* predstavlja odnos tačno klasifikovanih podataka prve klase i svih podataka koji stvarno pripadaju prvoj klasi, Formula 5.2.

$$\text{Precision} = \frac{TP}{TP + FP}. \quad (5.1)$$

$$\text{Recall} = \frac{TP}{TP + FN}. \quad (5.2)$$

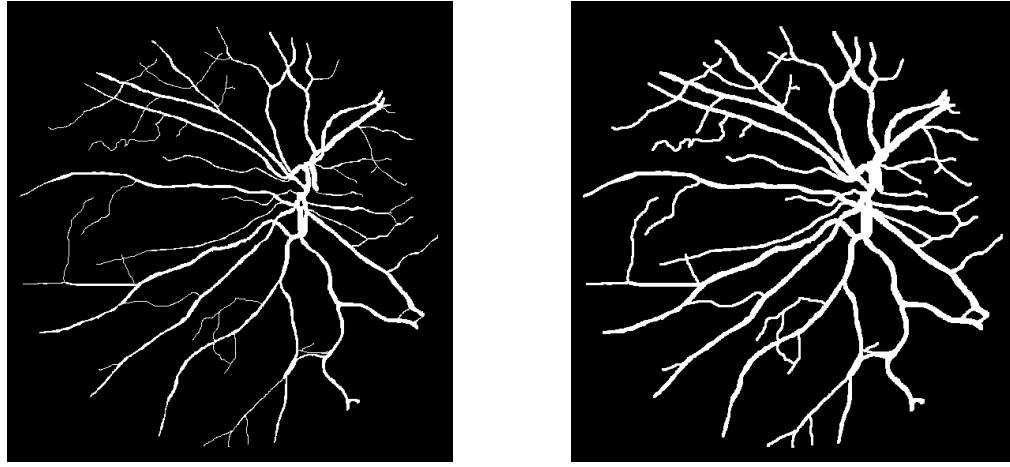
Kao što vidimo, *precision* i *recall* predstavljaju kontradiktorne pokazatelje performansi sistema. U slučaju kada želimo da obuhvatimo što veći broj piksela krvnih sudova, a na taj način kao posledicu ćemo da imamo veći broj piksela pozadine klasifikovanih kao krvni sud, *recall* će da ima veliku vrijednost, dok će *precision* da ima znatno manju vrijednost. Suprotno od toga, kada želimo da kažemo sa velikom sigurnošću da je klasifikovani piksel krvni sud, *precision* će da ima znatno veću vrijednost od *recall*-a. Iz tog razloga, *precision* i *recall* treba da imaju približno istu vrijednost i da teže jedinici.

Formula 5.3 predstavlja način dobijanja F_1 ocjene:

$$F_1 = 2 * \frac{\text{precision} * \text{recall}}{\text{precision} + \text{recall}}. \quad (5.3)$$

Treća metrika koja je korišćena za testiranje validnosti sistema jeste lokalna tačnost koja je isključivo vezana samo za ovaj problem. Kod ove metrike samo pikseli krvnih sudova i pozadinski pikseli u okolini krvnih sudova se uzimaju u obzir. Okolina krvnih sudova se određuje na sledeći način: nad slikom stručnjaka, koja se koristi kao referentna slika, se izvršava morfološki operator dilatacija sa kvadratom 3 piksela kao strukturnim elementom. Na ovaj način se izvršilo proširenje krvnih sudova, Slika 5.2b. Zatim se računa tačnost ne unutar čitvog FOV-a, već samo u pikselima prosirenh krvnih sudova.

Za testiranje sistema su korišćene testne slike DRIVE baze i trening slike STARE baze. Uz ove slike su dostupne ručno segmentirane slike od strane dva stručnjaka. Prije nego što krenemo sa prezentacijom naših rezultata i poređenjem sa ručno segmentiranim slikama, izvršeno je poređenje ručno segmentiranih slika između navedena dva stručnjaka koristeći navedene metrike. Na ovaj način je prikazano nepoklapanje između stručnjaka, a s obzirom da je samo jedan stručnjak dostupan za treniranje sistema jasno je da će i istrenirani sistem da ima nepoklapanja sa drugim stručnjacima. Za ovaj eksperiment kod DRIVE baze prvi stručnjak je korišćen kao referentni, dok je drugu posmatran kao rezultat. U slučaju STARE baze, drugi stručnjak je referentni, a prvi predstavlja rezultat. Kao referentni stručnjaci su odabrani oni stručnjaci koji su izvršili detaljniju segmentaciju krvnih sudova, to jest oni stručnjaci koji su segmentirali i najsitnije krvne sudove.



(a) Segmentirana testna slika DRIVE baze.

(b) Rezultat nakon dilatacije.

Slika 5.2: Lokalna tačnost.

U nastavku slijedi tabelarni prikaz minimalne, maksimalne i srednje vrijednosti tačnosti, F_1 ocjene i lokalne tačnosti stručnjaka koji se posmatra kao rezultat (S_{rez}) u odnosu na stručnjaka koji se posmatra kao referentni stručnjak (S_{ref}) testnih slika DRIVE baze i trening slika STARE baze, kao i grafički prikaz navedenih metrika pojedinačno za slike pomenutih baze.

Tabela 5.1: Minimalna, maksimalna i srednja vrijednost tačnosti S_{rez} u odnosu na S_{ref} testnih slika DRIVE i trening slika STARE baze.

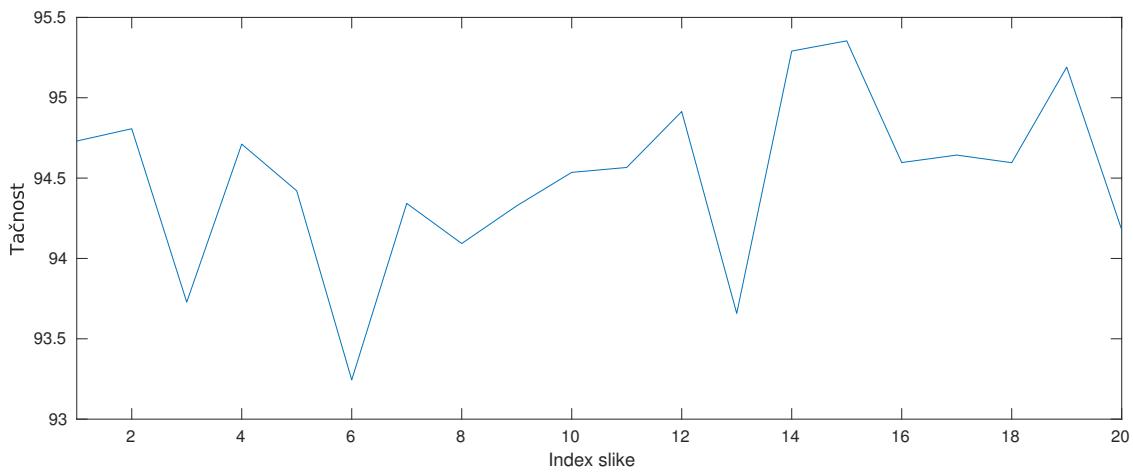
Baza	Tačnost	Minimalna tačnost	Maksimalna tačnost
DRIVE	94.4964%	93.2442%	95.3542%
STARE	93.8784%	89.8785%	96.8784%

Tabela 5.2: Minimalna, maksimalna i srednja vrijednost F_1 ocjene S_{rez} u odnosu na S_{ref} testnih slika DRIVE i trening slika STARE baze.

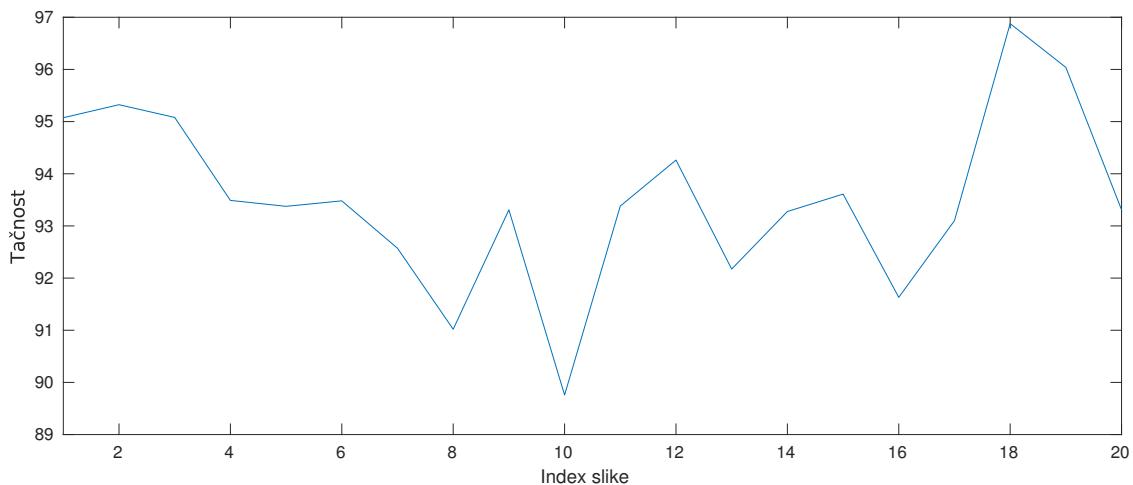
Baza	F_1 ocjena	Minimalna F_1 ocjena	Maksimalna F_1 ocjena
DRIVE	0.7928	0.7508	0.8348
STARE	0.7401	0.6750	0.7967

Tabela 5.3: Minimalna, maksimalna i srednja vrijednost lokalne tačnosti S_{rez} u odnosu na S_{ref} testnih slika DRIVE i trening slika STARE baze.

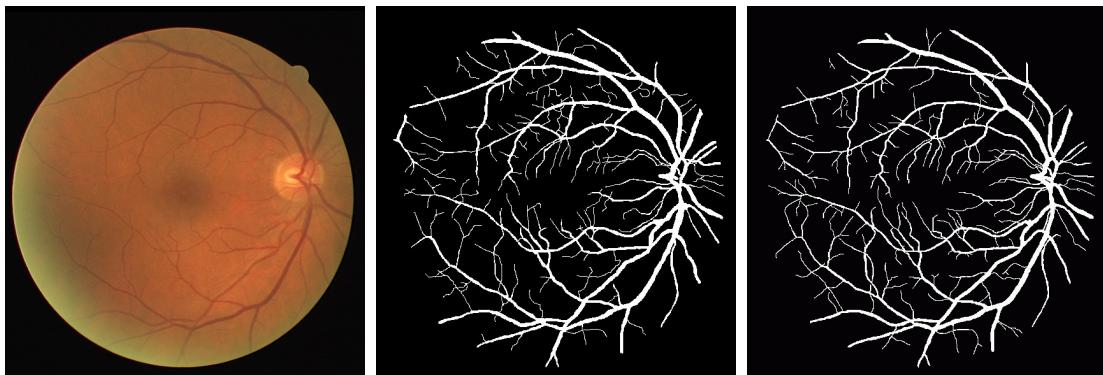
Baza	Lokalna tačnost	Minimalna lokalna tačnost	Maksimalna lokalna tačnost
DRIVE	0.7963	0.7617	0.8333
STARE	0.7451	0.6828	0.7921



Slika 5.3: Tačnost S_{rez} u odnosu na S_{ref} testnih slika DRIVE baze.



Slika 5.4: Tačnost S_{rez} u odnosu na S_{ref} trening slika STARE baze.

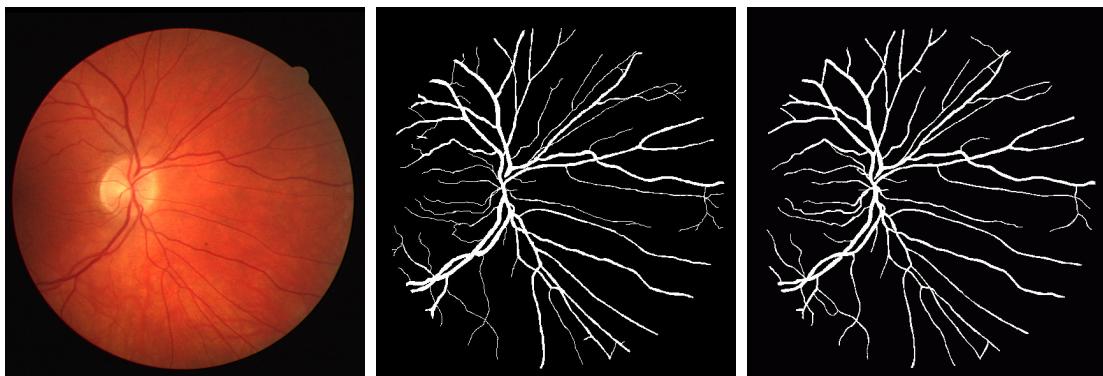


(a) RGB slika (index slike 6).

(b) Stručnjak 1.

(c) Stručnjak 2.

Slika 5.5: Slika sa najmanjom tačnošću između stručnjaka DRIVE baze.

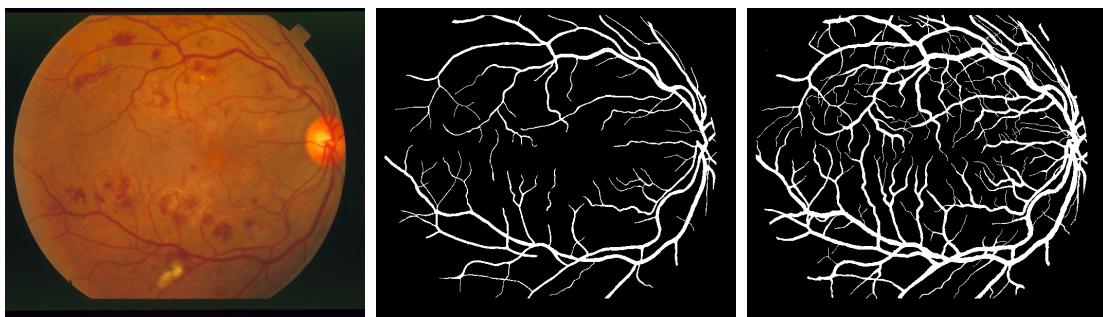


(a) RGB slika (index slike 15).

(b) Stručnjak 1.

(c) Stručnjak 2.

Slika 5.6: Slika sa najvećom tačnošću između stručnjaka DRIVE baze.

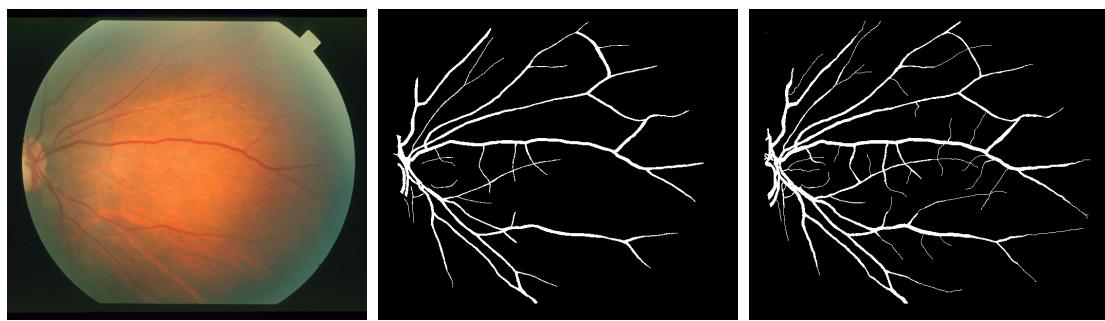


(a) RGB slika (index slike 10).

(b) Stručnjak 1.

(c) Stručnjak 2.

Slika 5.7: Slika sa najmanjom tačnošću između stručnjaka STARE baze.

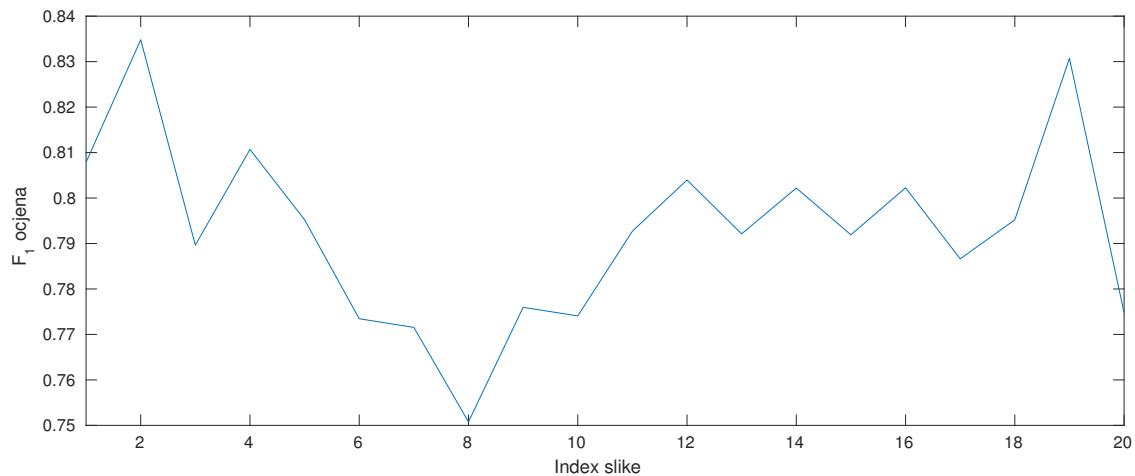


(a) RGB slika (index slike 18).

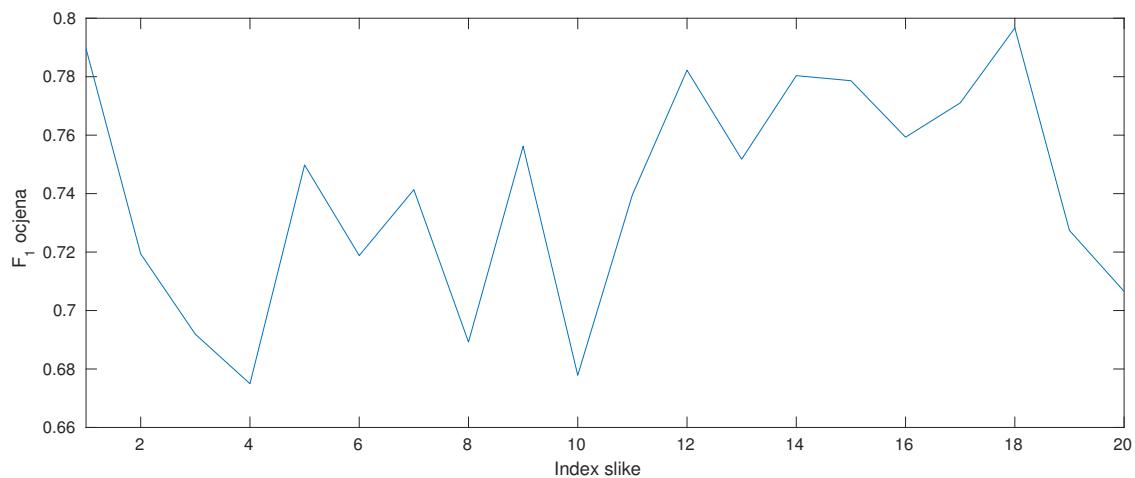
(b) Stručnjak 1.

(c) Stručnjak 2.

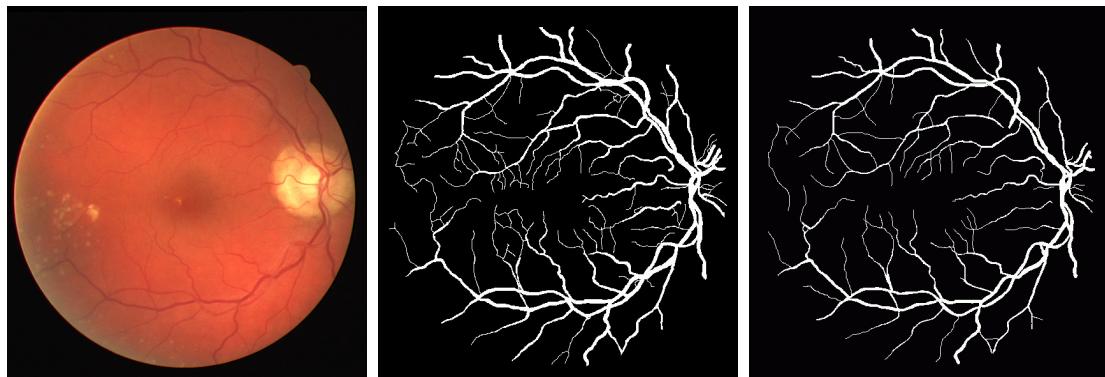
Slika 5.8: Slika sa najvećom tačnošću, F_1 ocjenom i lokalnom tačnošću između stručnjaka STARE baze.



Slika 5.9: F_1 ocjena S_{rez} u odnosu na S_{ref} testnih slika DRIVE baze.

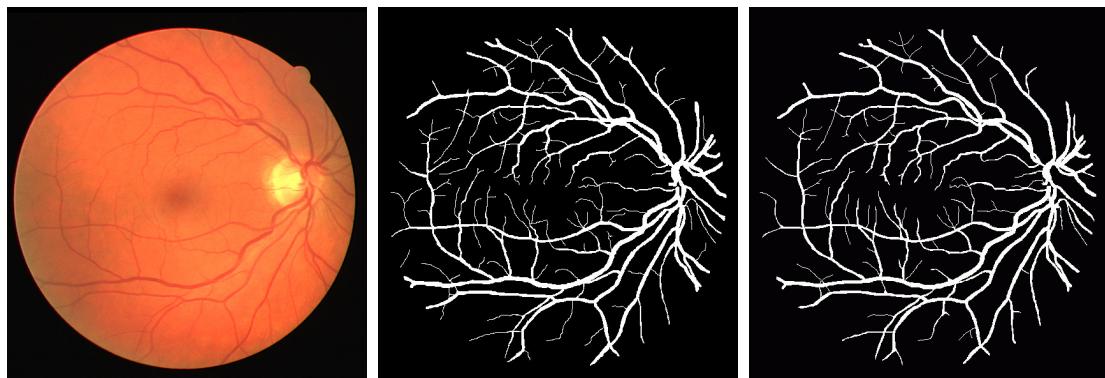


Slika 5.10: F_1 ocjena S_{rez} u odnosu na S_{ref} trening slika STARE baze.



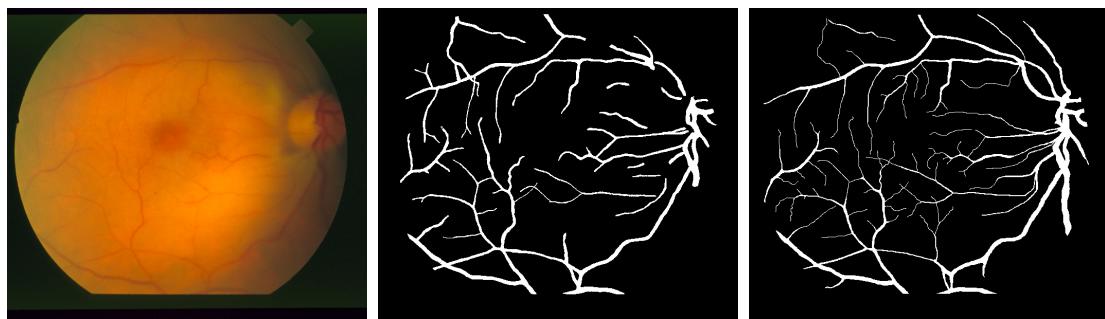
(a) RGB slika (index slike 8). (b) Stručnjak 1. (c) Stručnjak 2.

Slika 5.11: Slika sa najmanjom F_1 ocjenom i lokalnom tačnošću između stručnjaka DRIVE baze.



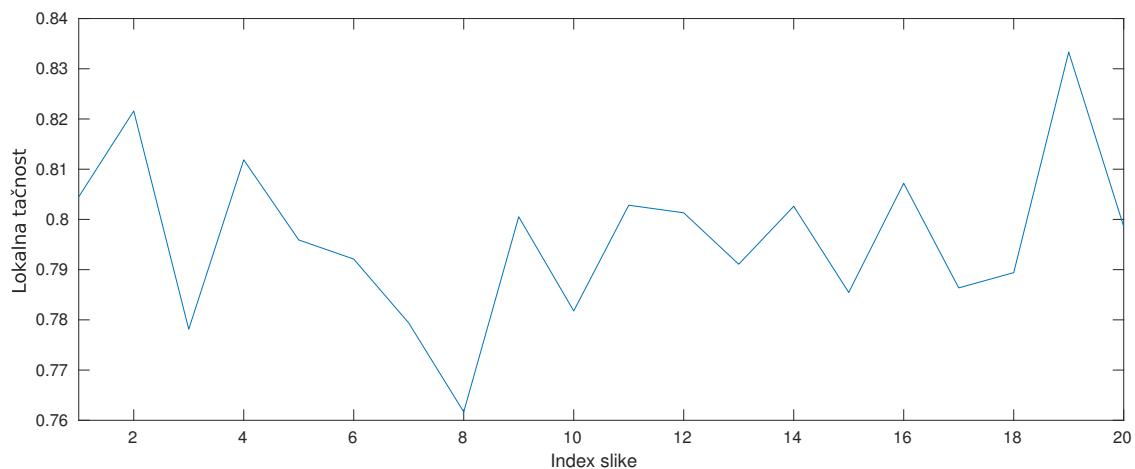
(a) RGB slika (index slike 2). (b) Stručnjak 1. (c) Stručnjak 2.

Slika 5.12: Slika sa najvećom F_1 ocjenom između stručnjaka DRIVE baze.

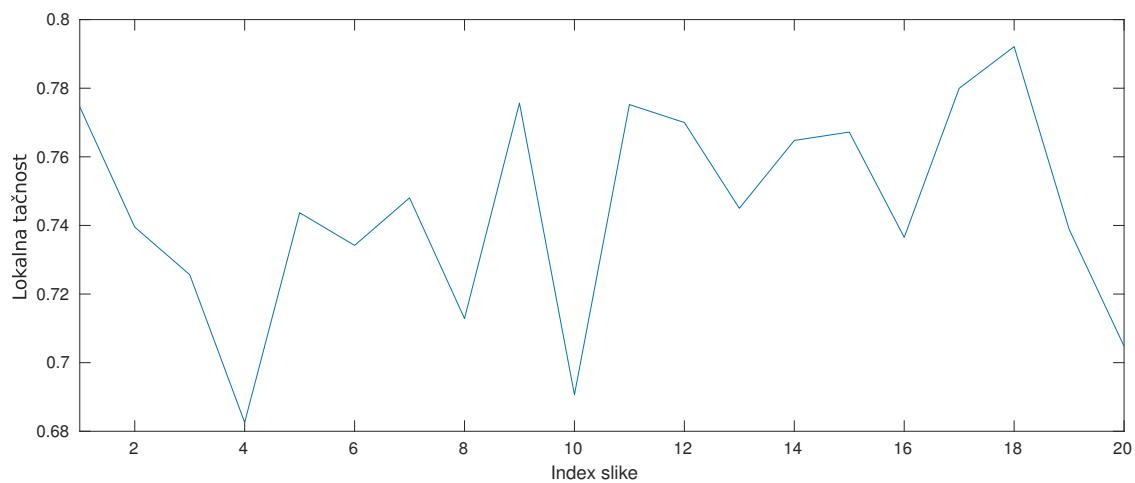


(a) RGB slika (index slike 4). (b) Stručnjak 1. (c) Stručnjak 2.

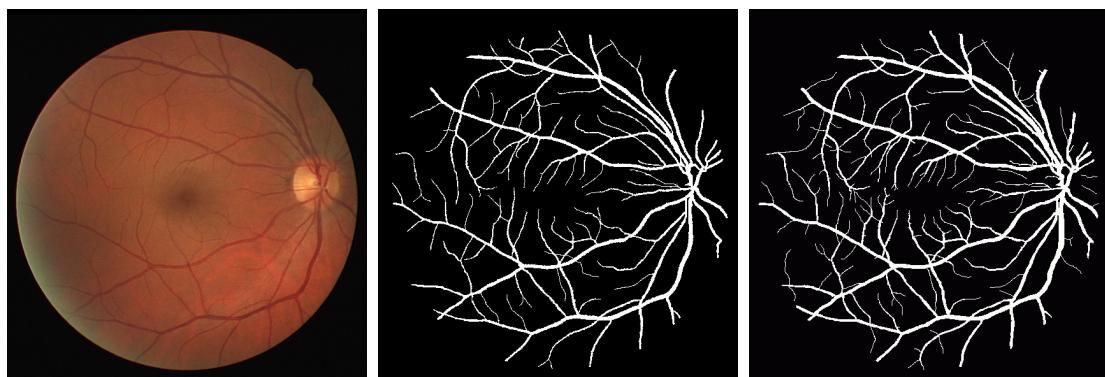
Slika 5.13: Slika sa najmanjom F_1 ocjenom i lokalnom tačnošću između stručnjaka STARE baze.



Slika 5.14: Lokalna tačnost S_{rez} u odnosu na S_{ref} testnih slika DRIVE baze.



Slika 5.15: Lokalna tačnost S_{rez} u odnosu na S_{ref} trening slika STARE baze.



(a) RGB slika (index slike 19).

(b) Stručnjak 1.

(c) Stručnjak 2.

Slika 5.16: Slika sa najvećom lokalnom tačnošću između stručnjaka DRIVE baze.

5.1 Algoritam kolonije mrava

Za funkcije feromona i heuristike korišćena je kombinacija linijskih karakteristika. Kako bi potkrijepili tvrdnje vezane za kombinovanu linijsku karakteristiku u ovom poglavlju biće izvršeni eksperimenti i prikazani rezultati koristeći navedene metrike za linijski detektor (karakteristika 2), linijski detektor sa ortogonalnom linijom (karakteristika 3) i kombinovanu karakteristiku (karakteristika C) kao funkcije feromona i heuristike.

5.1.1 Algoritam kolonije mrava sa linijskim detektorem

Prvi slučaj, to jest kada se karakteristika 2 koristi za dobijanje funkcija feromona i heuristike je predstavljen u ovom poglavlju. Grafički prikaz tačnosti, F_1 ocjene i lokalne tačnosti za testne slike DRIVE baze koje posjeduju ručno segmentirane slike od strane dva stručnjaka su date na Slikama 5.17., 5.19. i 5.21. Na Slikama 5.18., 5.20. i 5.22 su prikazani grafici navedenih metrika za trening slike STARE baze koje takođe posjeduju ručno segmentirane slike od strane dva stručnjaka i koje su korišćene za testiranje predloženih sistema. U Tabeli 5.4. su predstavljene srednje vrijednosti korišćenih matrika za DRIVE bazu, dok su u Tabeli 5.5. date srednje vrijednosti metrika za STARE bazu.

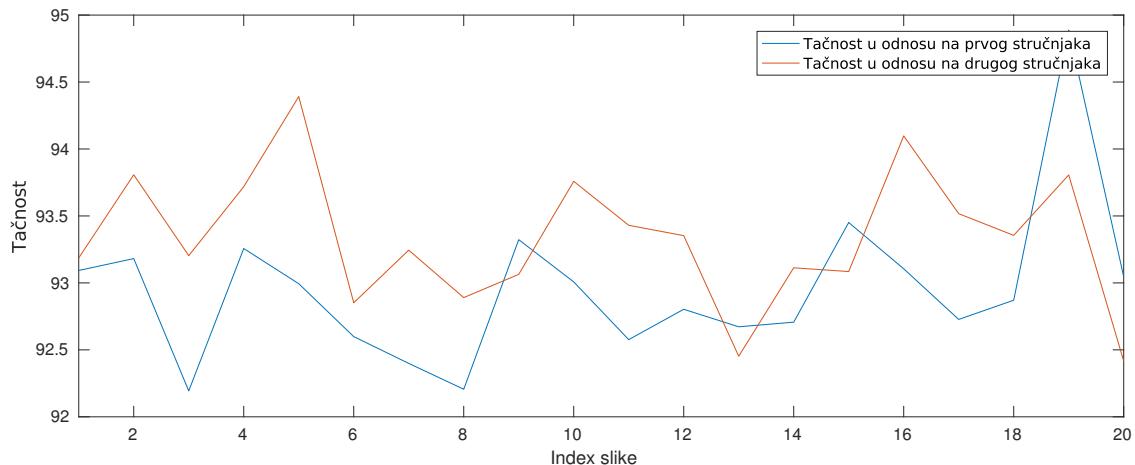
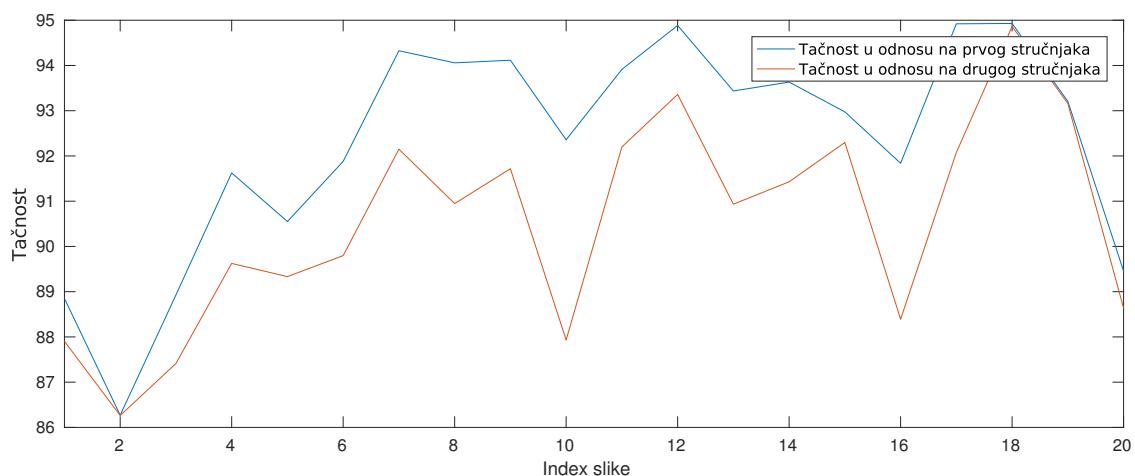
Primjenom karakteristike 2 za dobijanje funkcija feromona i heuristike smo izvršili dobru detekciju krvnih sudova uz problem detekcije graničnih piksela pozadina-krvni sud, Slika 5.23d., 5.24d. Do pomenute greške se dolazi zbog same prirode detektora, jer se traži linija sa maksimalnom srednjom vrijednošću. Na taj način će i pikseli koji se nalaze do krvnih sudova da dobiju značajnu vrijednost. Još jedna bitna greška koju unosi pomenuti detektor jeste greška kada su dva krvna suda bliska, to jest jedan blizu drugog. Tada će linijski detektor i pozadinske piksele koji se nalaze između da proglaši pikselima krvnih sudova, odnosno izvršiće spajanje krvnih sudova. Pod bliskim krvnim sudovima se misli na krvne sudove koji su na rastojanju manjem od veličine maske (u našem slučaju 15 piksela). U ovom slučaju, kada maska obuhvati i jedan i drugi krvni sud, tada će njena maksimalna linija (koja ujedno i predstavlja vrijednost novodobijenog centralnog piksela maske, to jest vrijednost piksela u karakteristici) da dobije određenu vrijednost krvnog suda, i na taj način će da se napravi greška prilikom klasifikacije pomenutih piksela. Ova situacija je prikazana na Slici 5.25a.

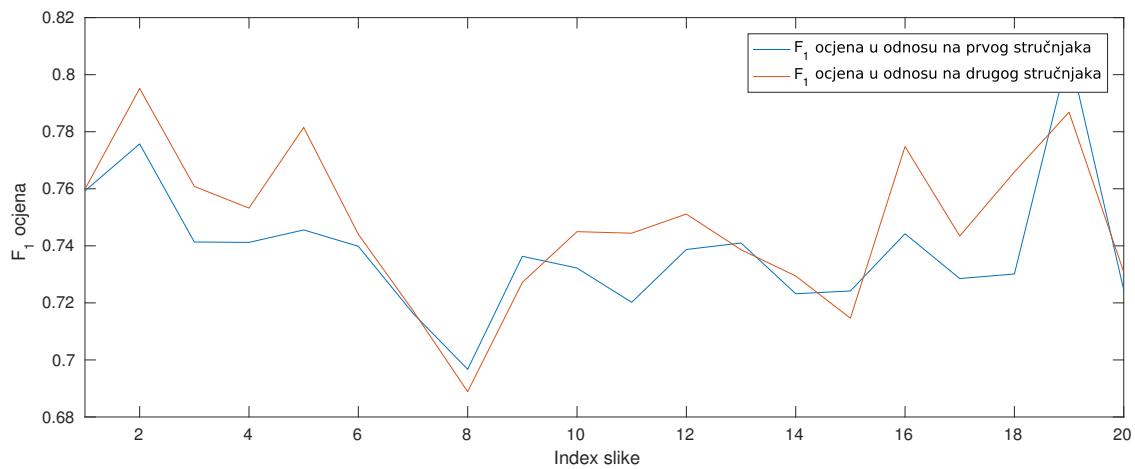
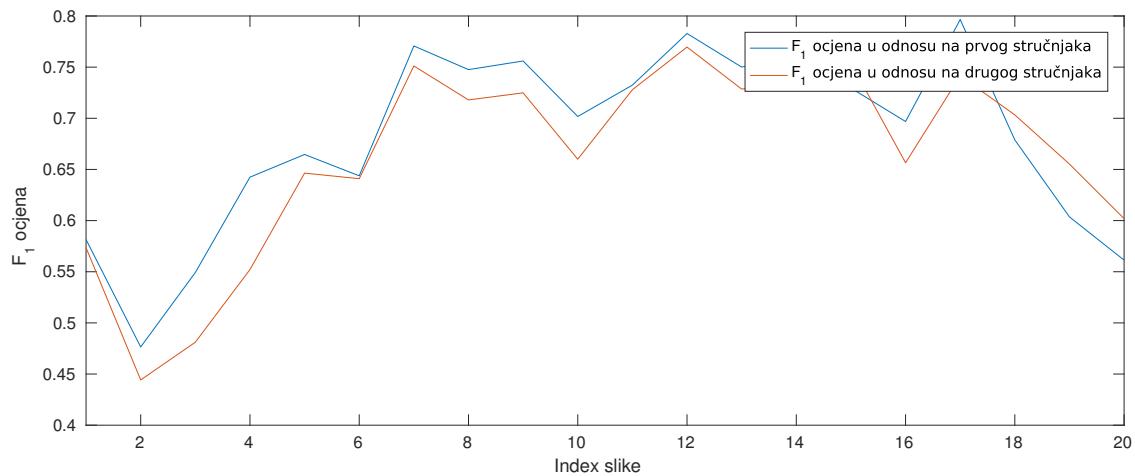
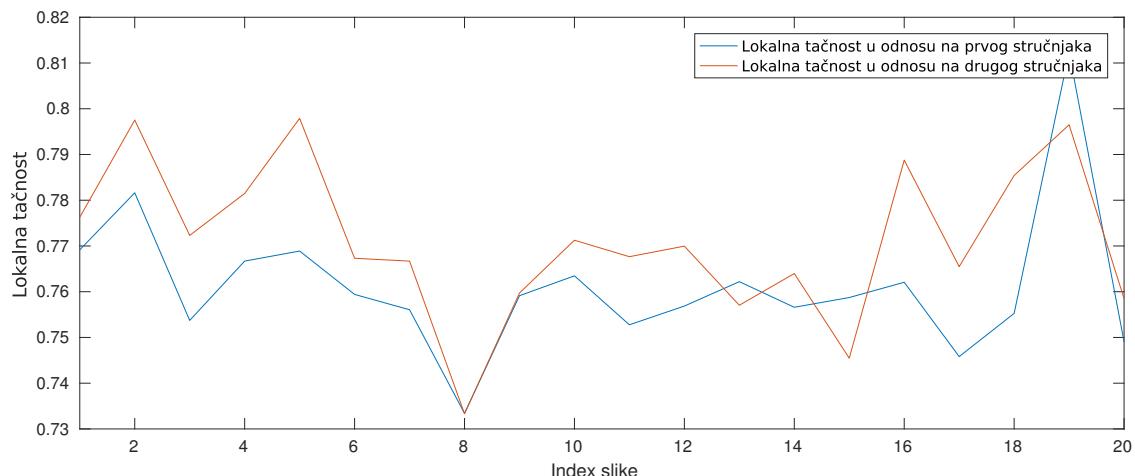
Tabela 5.4: Metrike na DRIVE bazi sa karakteristikom 2.

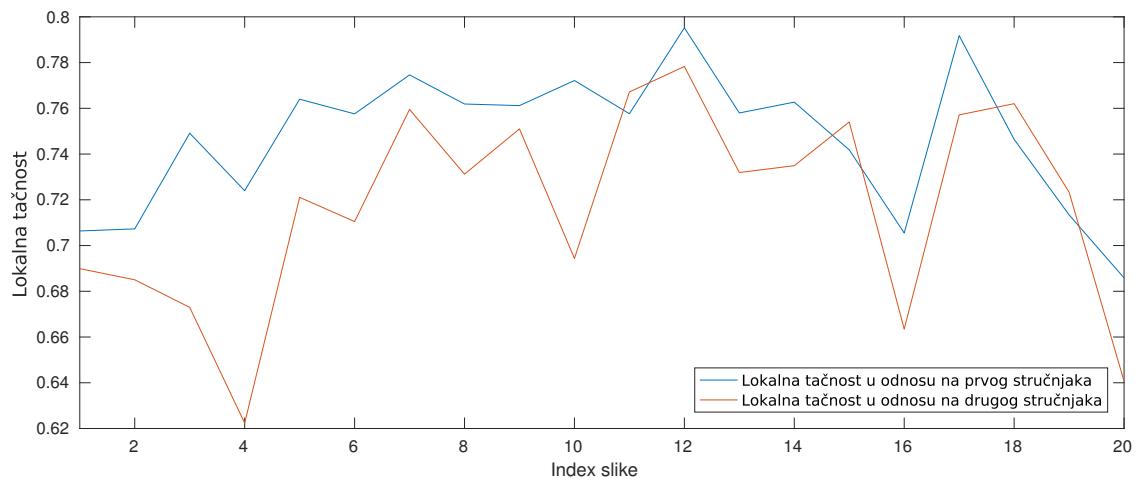
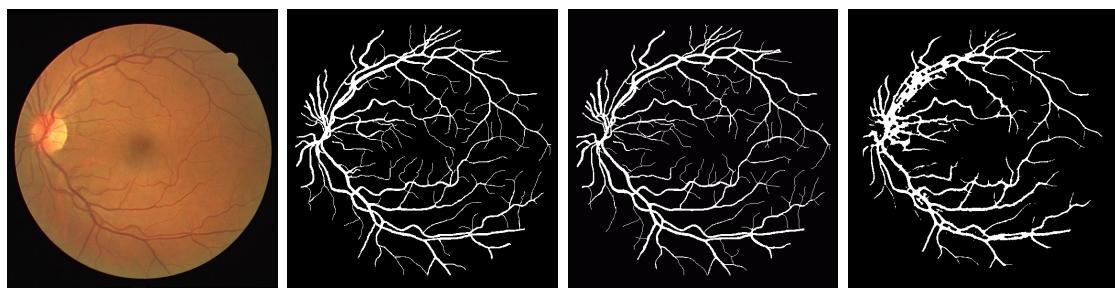
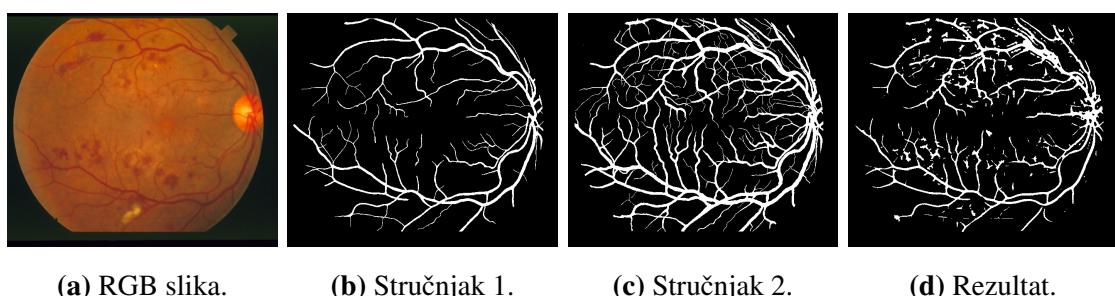
Stručnjak	Tačnost	F_1 ocjena	Lokalna tačnost
Stručnjak 1	92.955%	0.7384	0.7612
Stručnjak 2	93.3371%	0.7477	0.7711

Tabela 5.5: Metrike na STARE baze sa karakteristikom 2.

Stručnjak	Tačnost	F_1 ocjena	Lokalna tačnost
Stručnjak 1	92.3077%	0.6813	0.7468
Stručnjak 2	90.5217%	0.6633	0.7175

**Slika 5.17:** Tačnost sistema sa karakteristikom 2 na DRIVE bazi.**Slika 5.18:** Tačnost sistema sa karakteristikom 2 na STARE bazi.

**Slika 5.19:** F_1 ocjena sistema sa karakteristikom 2 na DRIVE bazi.**Slika 5.20:** F_1 ocjena sistema sa karakteristikom 2 na STARE bazi.**Slika 5.21:** Lokalna tačnost sistema sa karakteristikom 2 na DRIVE bazi.

**Slika 5.22:** Lokalna tačnost sistema sa karakteristikom 2 na STARE bazi.**Slika 5.23:** Testna slika DRIVE baze.**Slika 5.24:** Trening slika STARE baze.

5.1.2 Algoritam kolonije mrava sa linijskim detektorom sa ortogonalnom linijom

Da bi riješili navedene probleme koje izaziva karakteristika 2 uzima se u obzir linijski detektor sa ortogonalnom linijom (karakteristikom 3). Primjenom ove karakteristike dobili smo jasnu granicu oko krvnih sudova, Slika 5.25., jer se u odnosu na posmatrani piksel, koji predstavlja centralni piksel maske u kojoj se traži maksimalna linija, uzima ortogonalna linija dužine tri piksela. Na ovaj način ako je centralni piksel pozadinski, a maksimalna linija obuhvati venu, tad će njena tri piksel ortogonalna linija da obuhvati pozadinske piksele. Međutim, nedostatak ovog detektora jeste što unosi šum, Slike 5.32d., 5.33d., što utiče u velikoj mjeri na tačnost i F_1 ocjenu.



Slika 5.25: DRIVE baza.

U Tabelama 5.6. i 5.7. su predstavljene srednje vrijednosti tačnosti, F_1 ocjene i lokalne tačnosti za testne slike DRIVE baze i trening slike STARE baze, respektivno, u odnosu na slike ručno segmentirane od strane dva stručnjaka primjenom karakteristike 3. Vidimo da imamo slabiju tačnost i F_1 ocjenu u odnosu na karakteristiku 2, što je i očekivano zbog šuma koji unosi ovaj detektor.

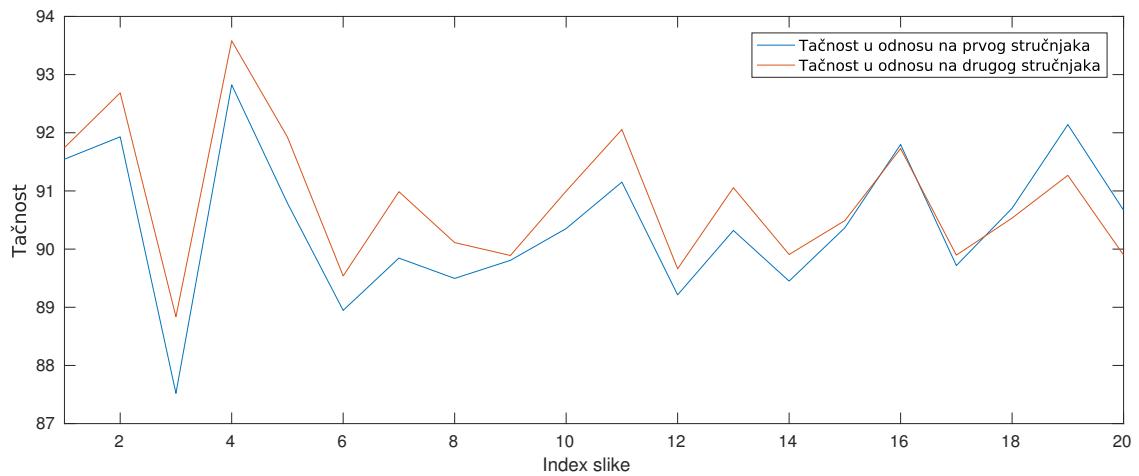
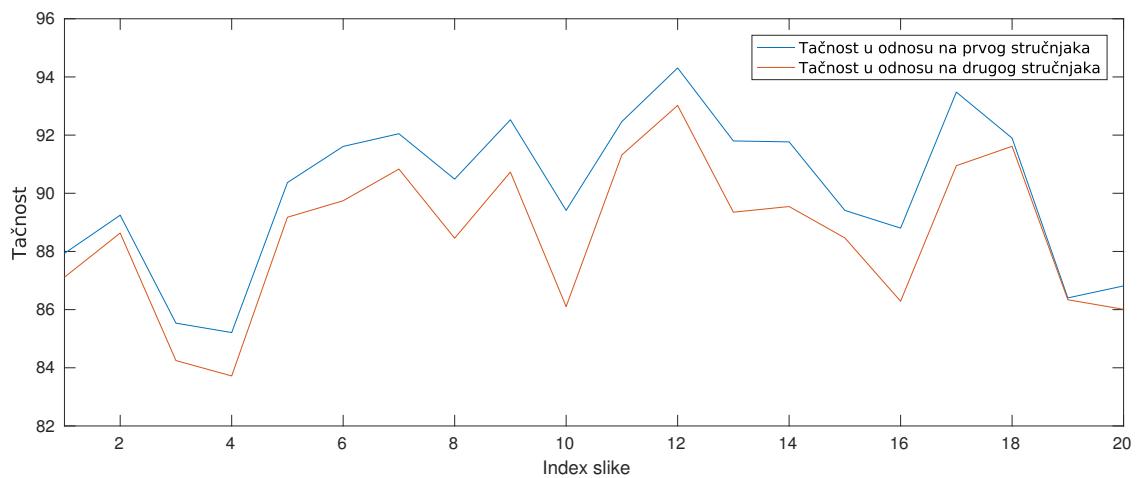
Tačnost, F_1 ocjena i lokalna tačnost sistema na testnim slikama DRIVE baze i trening slikama STARE baze kada se karakteristika 3 koristi za dobijanje funkcija feromona i heuristike su predstavljeni graficima na Slikama 5.26.-5.31.

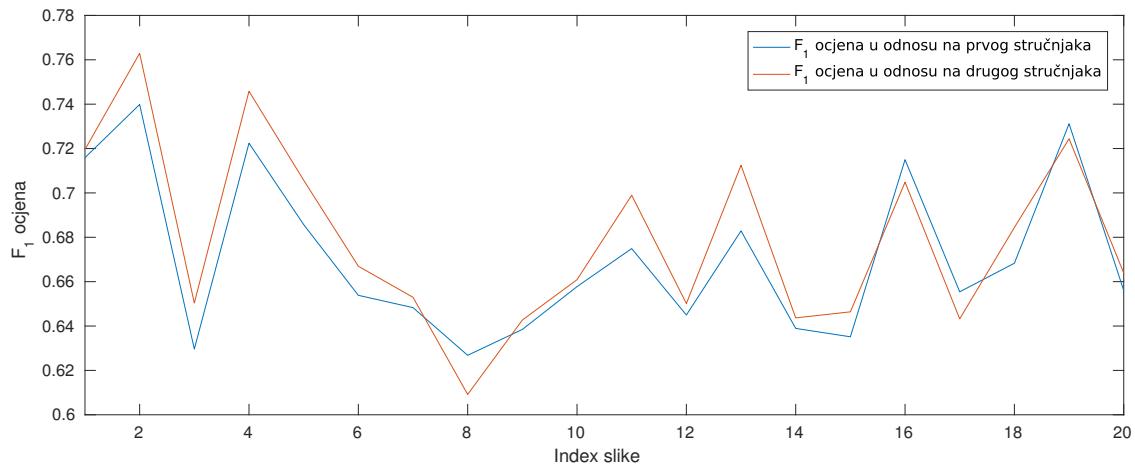
Tabela 5.6: Metrike na DRIVE bazi sa karakteristikom 3.

Stručnjak	Tačnost	F_1 ocjena	Lokalna tačnost
Stručnjak 1	90.4296%	0.6711	0.7499
Stručnjak 2	90.8398%	0.6795	0.7616

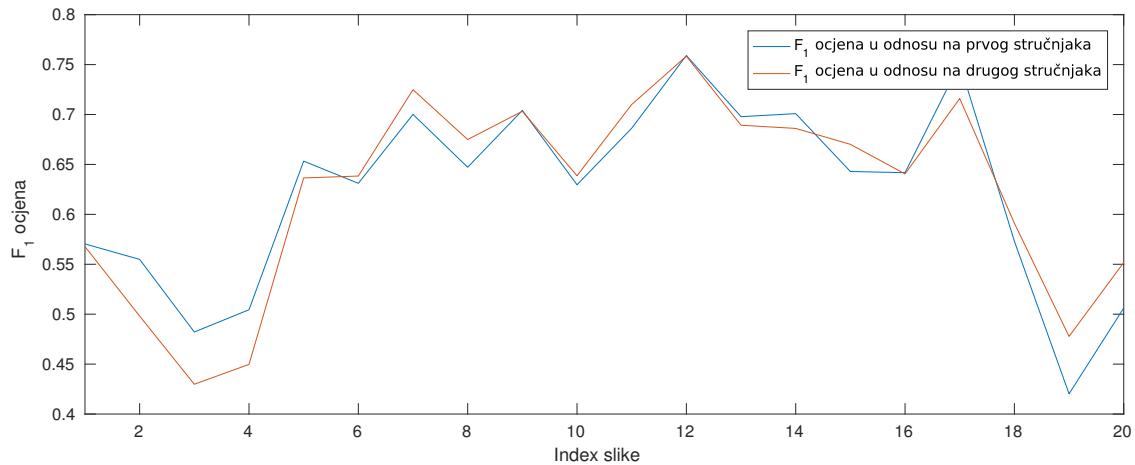
Tabela 5.7: Metrike na STARE baze sa karakteristikom 3.

Stručnjak	Tačnost	F_1 ocjena	Lokalna tačnost
Stručnjak 1	90.0762%	0.6228	0.7556
Stručnjak 2	88.5829%	0.6227	0.7166

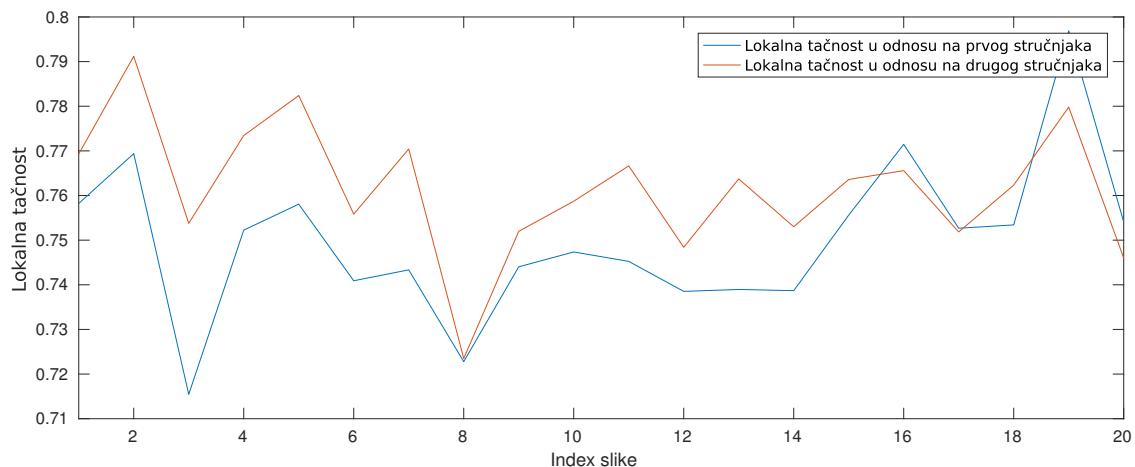
**Slika 5.26:** Tačnost sistema sa karakteristikom 3 na DRIVE bazi.**Slika 5.27:** Tačnost sistema sa karakteristikom 3 na STARE bazi.



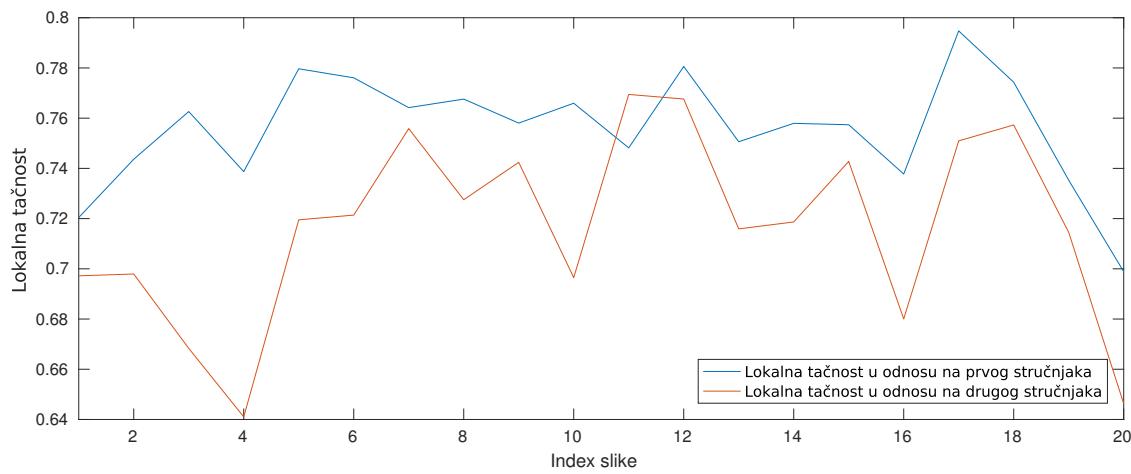
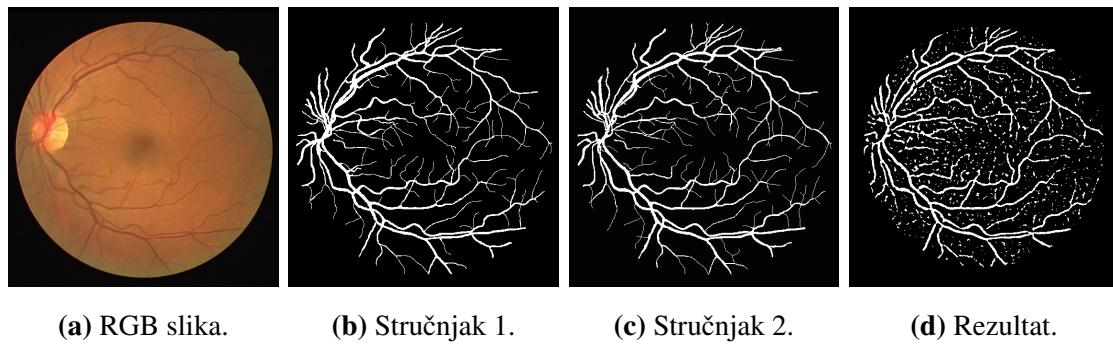
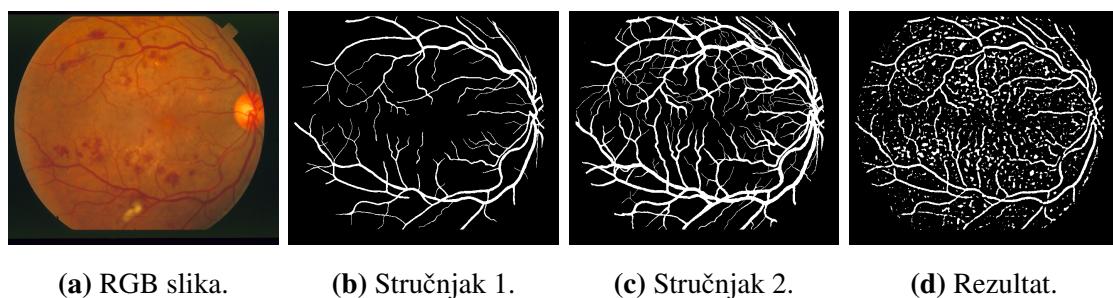
Slika 5.28: F_1 ocjena sistema sa karakteristikom 3 na DRIVE bazi.



Slika 5.29: F_1 ocjena sistema sa karakteristikom 3 na STARE bazi.



Slika 5.30: Lokalna tačnost sistema sa karakteristikom 3 na DRIVE bazi.

**Slika 5.31:** Lokalna tačnost sistema sa karakteristikom 3 na STARE bazi.**Slika 5.32:** Testna slika DRIVE baze.**Slika 5.33:** Trening slika STARE baze.

5.1.3 Algoritam kolonije mrava sa kombinovanom karakteristikom

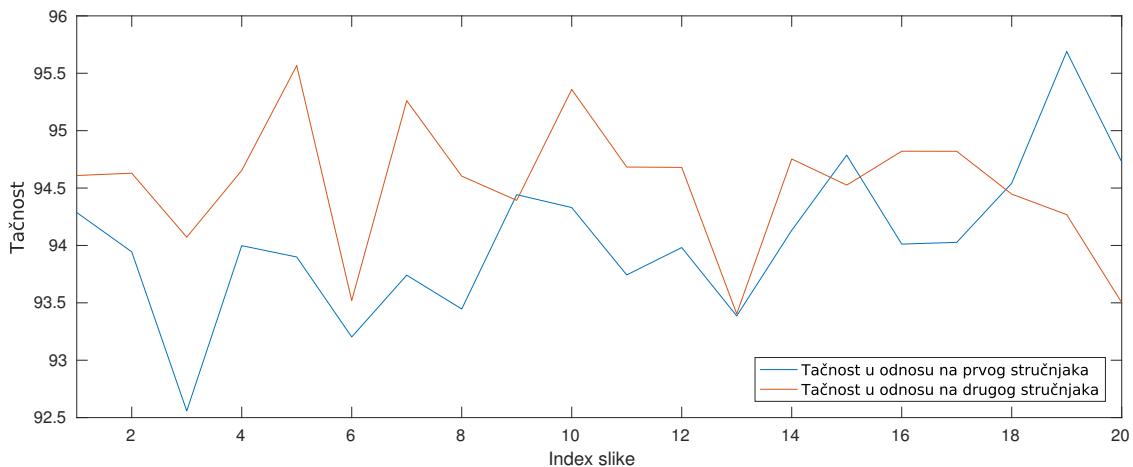
Nakon što smo predstavili performanse sistema pojedinačno za karakteristiku 2 i 3 i ukazali na njihove prednosti i nedostatke, predstavićemo performanse sistema sa kombinovanom karakteristikom (karakteristika C), što predstavlja Sistem 1. U Tabelama 5.8. i 5.9. su predstavljene performanse sistema za dva stručnjaka DRIVE i STARE baza, respektivno. Na Slikama 5.34.-5.39. su grafički prikazane tačnost, F_1 ocjena i lokalna tačnost u odnosu na stručnjake DRIVE i STARE baze.

Tabela 5.8: Metrike na DRIVE bazi sa karakteristikom C.

Stručnjak	Tačnost	F_1 ocjena	Lokalna tačnost
Stručnjak 1	94.0438%	0.7581	0.7685
Stručnjak 2	94.5287%	0.7733	0.7825

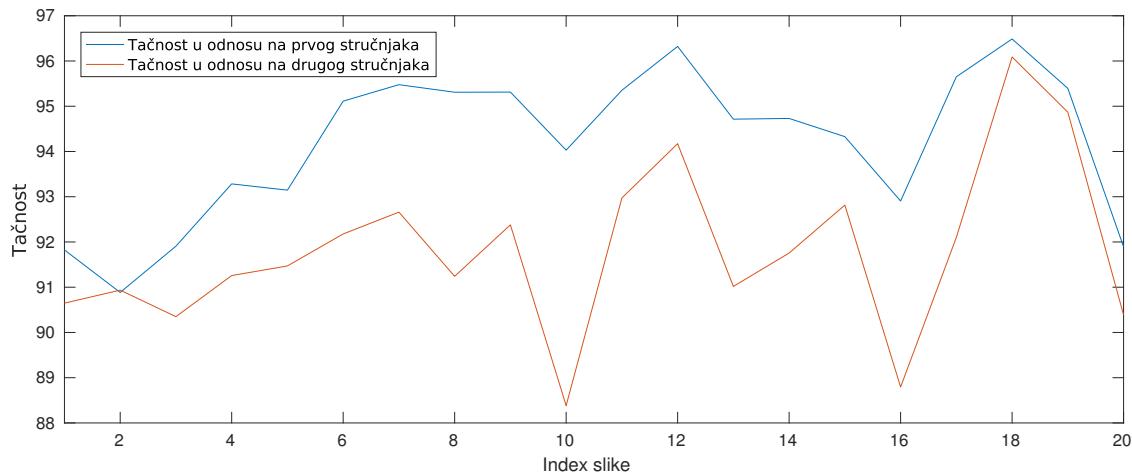
Tabela 5.9: Metrike na STARE baze sa karakteristikom C.

Stručnjak	Tačnost	F_1 ocjena	Lokalna tačnost
Stručnjak 1	94.2033%	0.7291	0.7569
Stručnjak 2	91.8237%	0.6810	0.7149

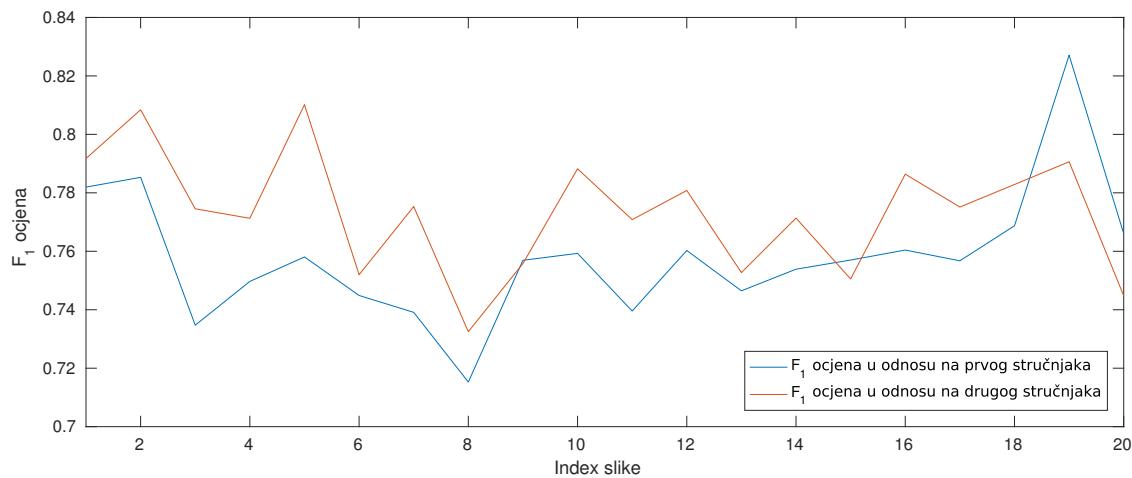


Slika 5.34: Tačnost sistema sa karakteristikom C na DRIVE bazi.

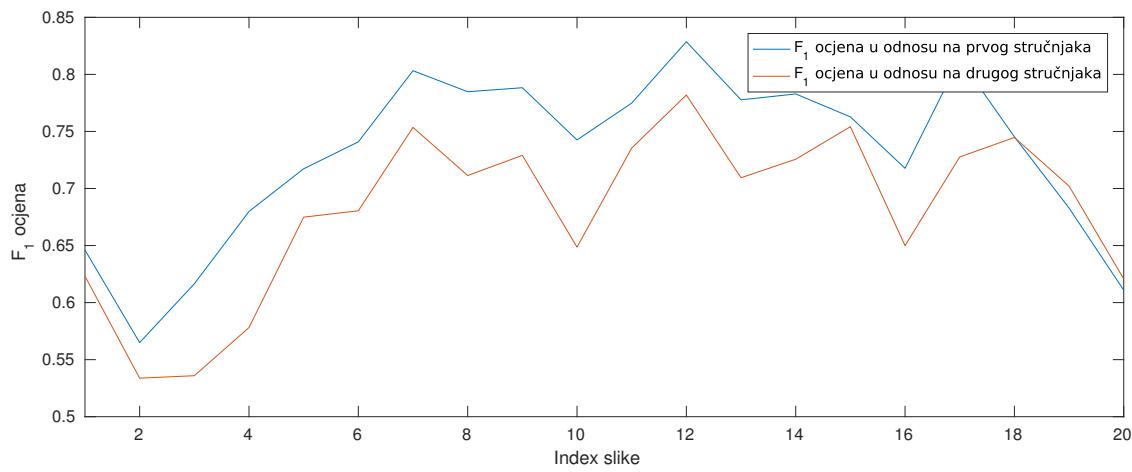
Iz Tabele 5.10. se može vidjeti da najbolje performanse za sve tri metrike daje sistem sa karakteristikom C, to jest sa kombinovanom karakteristikom, čime smo i potkrijepili



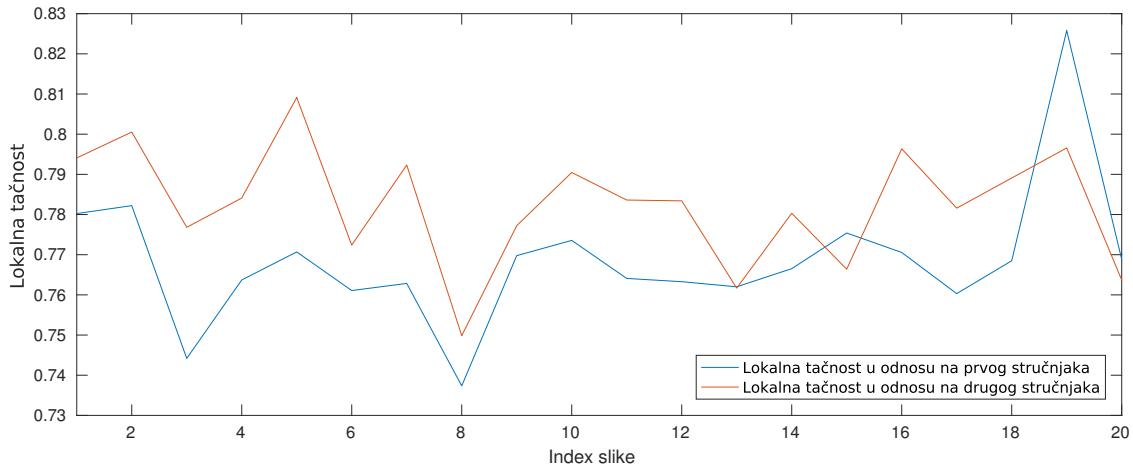
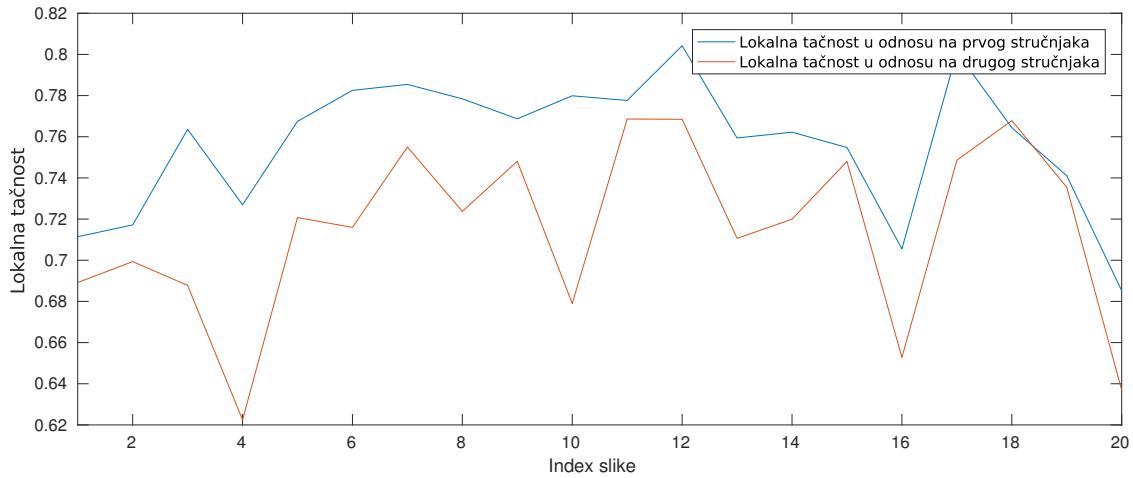
Slika 5.35: Tačnost sistema sa karakteristikom C na STARE bazi.



Slika 5.36: F_1 ocjena sistema sa karakteristikom C na DRIVE bazi.

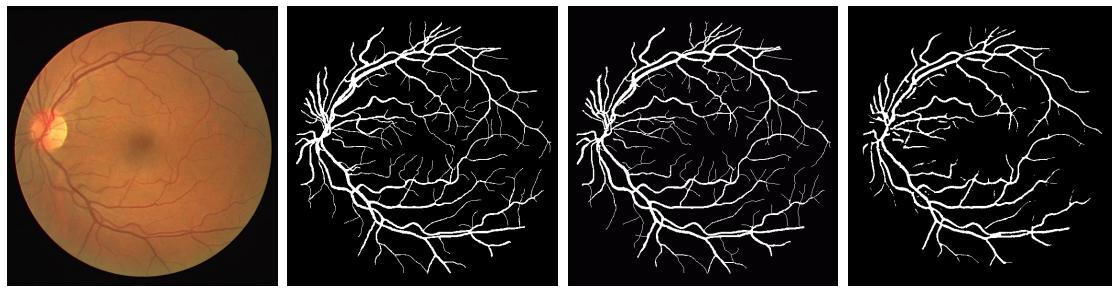


Slika 5.37: F_1 ocjena sistema sa karakteristikom C na STARE bazi.

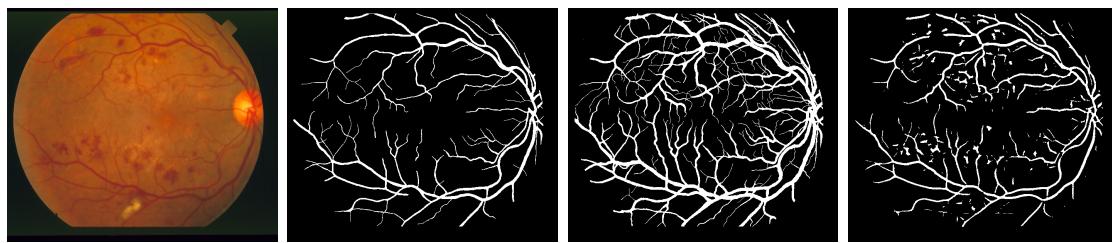
**Slika 5.38:** Lokalna tačnost sistema sa karakteristikom C na DRIVE bazi.**Slika 5.39:** Lokalna tačnost sistema sa karakteristikom C na STARE bazi.

naše tvrdnje. Za STARE bazu u ovoj tabeli poređenje je vršeno u odnosu na prvog stručnjaka, dok je za DRIVE bazu drugi stručnjak korišćen kao referentni stručnjak. Takođe, vidimo da sistem daje nešto slabije rezultate na STARE bazi za svaku od karakteristika. Razlog zbog kojeg je to tako, jeste što od 20 trening slika STARE baze koje se koriste za testiranje ovog sistema čak 10 slika sadrži piksele koji predstavljaju ostećenje mrežnjače usled nekog oboljenja. Da bi riješili ovaj problem potrebno je uvesti novu karakteristiku koja će jasno da pravi razliku između piksela oboljelih oblasti i piksela krvnih sudova, a zatim izvršiti njenu kombinaciju sa karakteristikom C, ili pak preprocesiranjem slike karakteristike C odstraniti oboljele oblasti.

Na Slici 5.42. je prikazana RGB testna slika DRIVE baze (Slika 5.42a.) i njene segmentirane slike od strane predloženog sistema koristeći: karakteristiku 2 (Slika 5.42b.)



(a) RGB slika. (b) Stručnjak 1. (c) Stručnjak 2. (d) Izlaz Sistema 1.

Slika 5.40: Testna slika DRIVE baze.

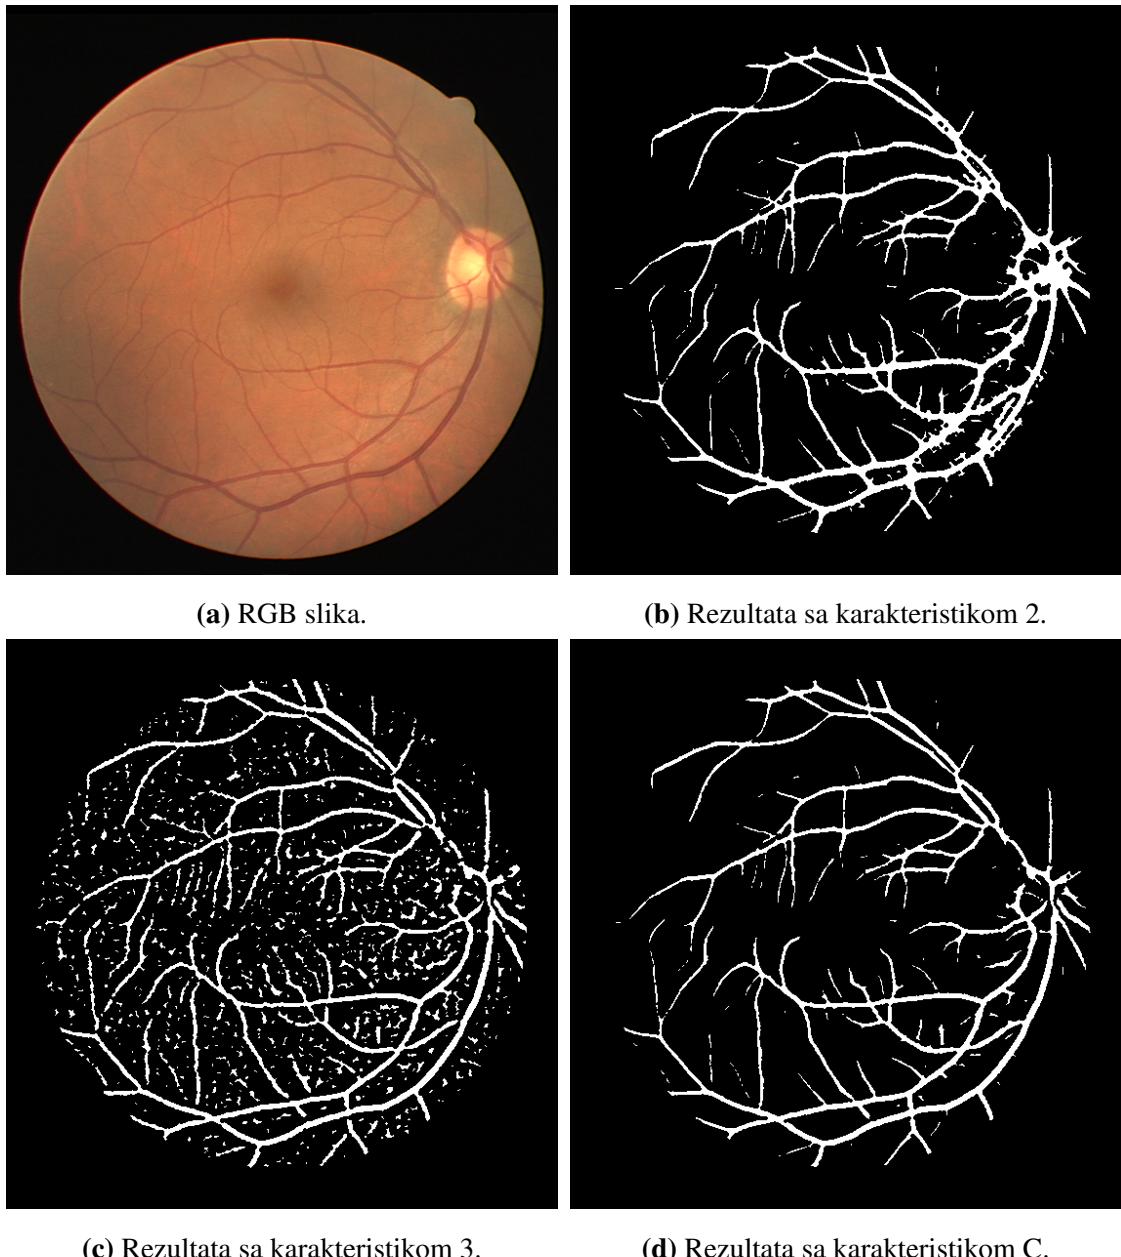
(a) RGB slika. (b) Stručnjak 1. (c) Stručnjak 2. (d) Izlaz Sistema 1.

Slika 5.41: Trening slika STARE baze.

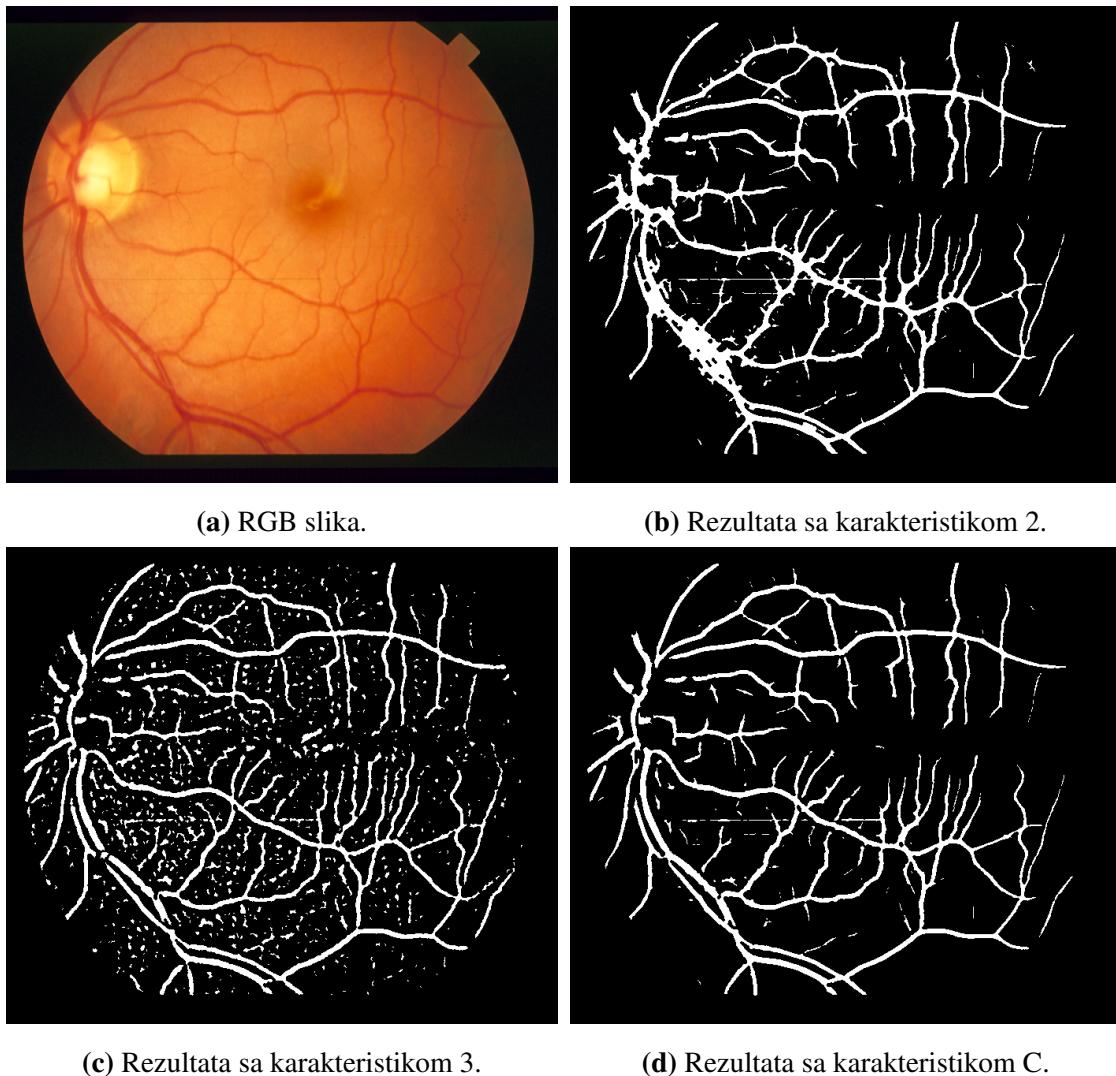
ili karakteristiku 3 (Slika 5.42c.) ili karakteristiku C (Slika 5.42d.) za dobijanje funkcija feromona i heuristike. Na Slici 5.43. je na identičan način predstavljena jedna od trening slika STARE baze.

Tabela 5.10: Metrike na STARE i DRIVE bazama.

Baza	Karakteristika	Tačnost	F_1 ocjena	Lokalna tačnost
DRIVE	Karakteristika 2	93.3371%	0.7477	0.7711
DRIVE	Karakteristika 3	90.8398%	0.6795	0.7616
DRIVE	Karakteristika C	94.5287%	0.7733	0.7825
STARE	Karakteristika 2	92.3077%	0.6813	0.7468
STARE	Karakteristika 3	90.0762%	0.6228	0.7556
STARE	Karakteristika C	94.2033%	0.7291	0.7569



Slika 5.42: Testna slika DRIVE baze.



Slika 5.43: Trening slika STARE baze.

5.2 Neuralna mreža

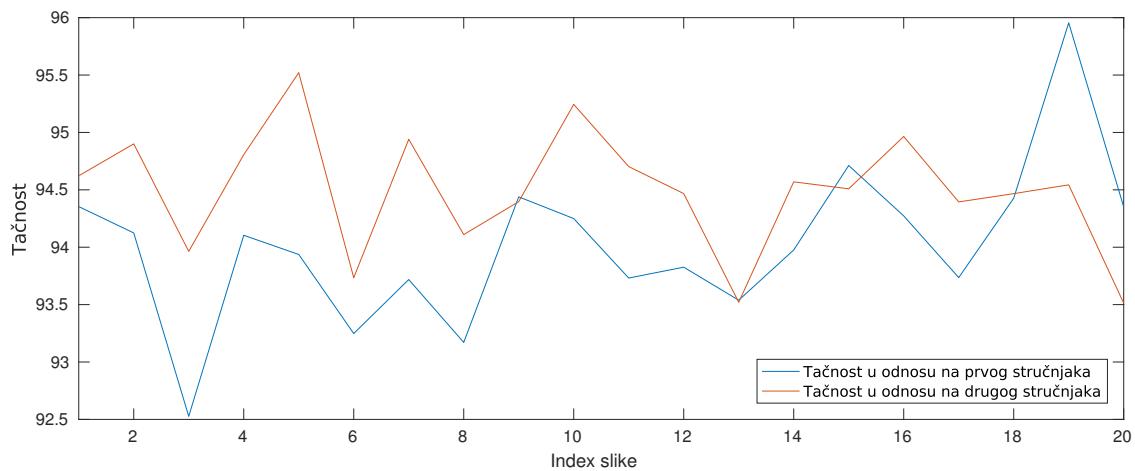
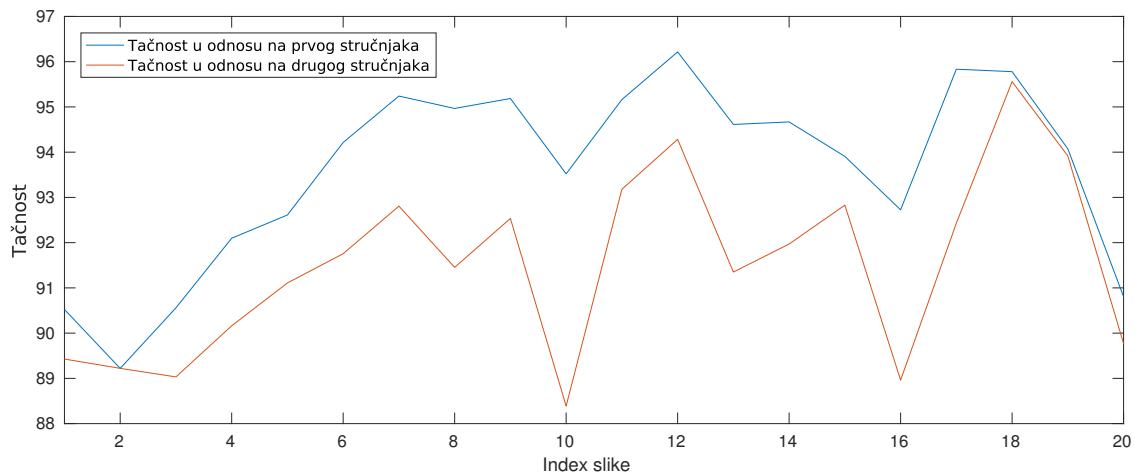
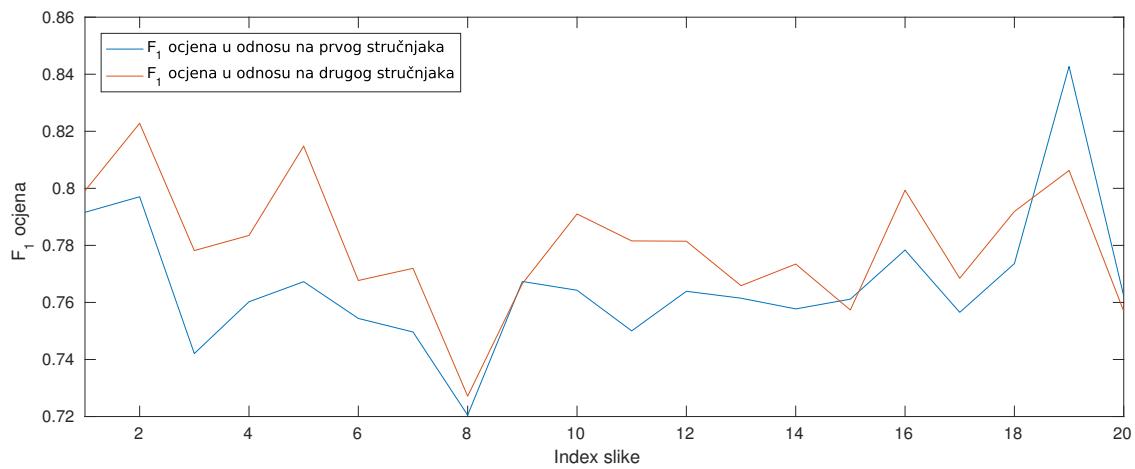
Drugi sistem koje je korišćen za segmentaciju krvnih sudova u ovom radu je sistem sa neuralnom mrežom (Sistem 2). S obzirom da se radi o algoritmu koji pripada grupi algoritama sa nadgledanjem, bilo je potrebno izvršiti treniranje sistema. Treniranje sistema je vršeno sa 20000 piksela koji su slučajno odabrani iz trening slika DRIVE baze, od toga 10000 piksela pozadine i 10000 piksela krvnih sudova. Sistem je treniran kroz 500 epoha, a modifikacija koeficijenata je vršena primjenom LMS algoritma sa korakom spuštanja $\mu = 0.1$. Ulagne karakteristike, to jest ulazni podaci u Sistem 2 su: inverzni zeleni kanal, linijski detektor i linijski detektor sa ortogonalnom linijom.

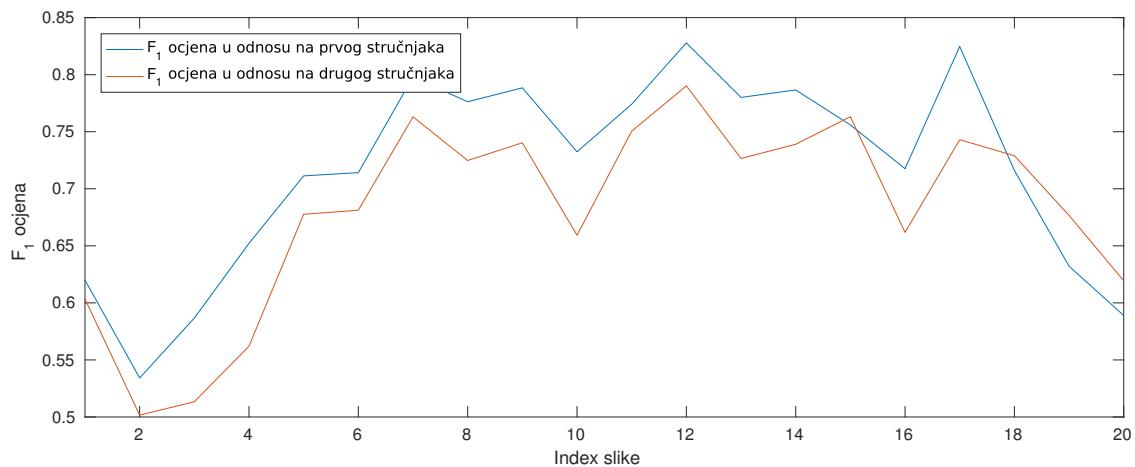
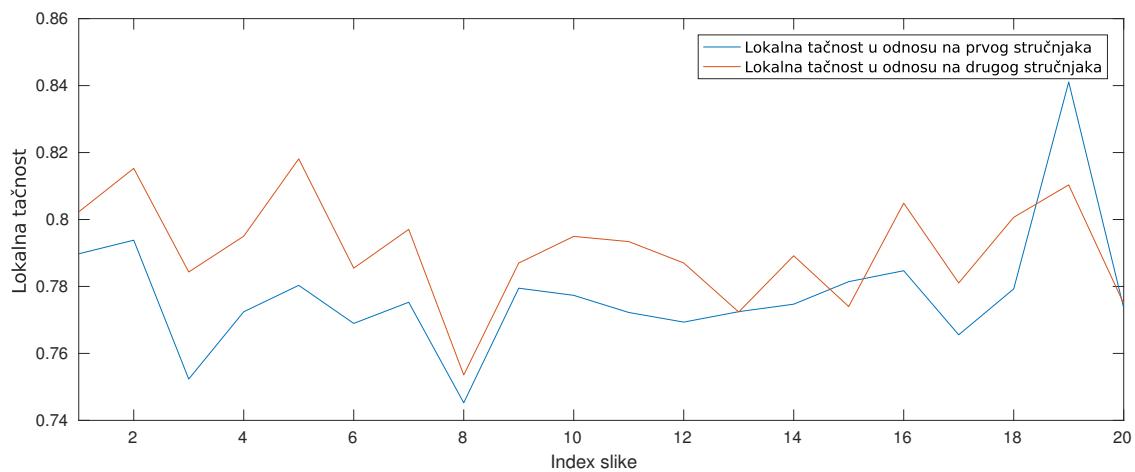
Nakon treniranje sistema izvršeno je testiranje na testnim slikama DRIVE baze i treninu sliku STARE baze. Na Slikama 5.44.-5.49. su prikazane performanse sistema koristeći navedene metrike u odnosu na odgovarajuće stručnjake DRIVE i STARE baze.

Tabela 5.11. predstavlja srednje vrijednosti tačnosti, F_1 ocjene i lokalne tačnosti slika DRIVE i STARE baze koje su korišćene za testiranje sistema u odnosu na odgovarajuće stručnjake. Što se tiče DRIVE baze, sistem sa neuralnom mrežom daje bolje rezultate u dvije metrike: F_1 ocjena i lokalna tačnost, koje predstavljaju bolje, to jest adekvatnije metrike za prezentaciju performansi sistema za problem segmentacije krvnih sudova mrežnjače očnog dna. Kod STARE baze sistem sa neuralnom mrežom daje bolji rezultat u pogledu lokalne tačnosti, dok u ostale dvije metrike sistem sa algoritmom kolonije mrava daje nešto bolje rezultate. Ako se uzme u obzir da je lokalna tačnost jedina metrika koja razmatra samo piksele krvnih sudova i piksele u okolini krvnih sudova, onda se može lako doći do zaključka da Sistem 2 daje bolje rezultate, to jest vrši bolju segmentaciju krvnih sudova mrežnjače očnog dna, ali je i više osjetljiv na oboljenja koja se manifestuju na mrežnjači očnog dna, što utiče na smanjenje tačnosti i F_1 ocjene.

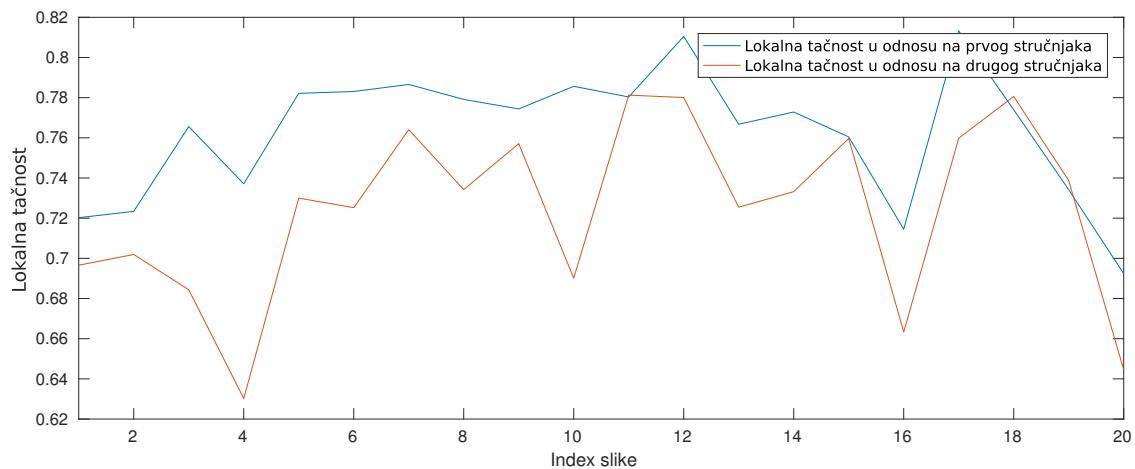
Tabela 5.11: Metrike na STARE i DRIVE bazama.

Baza	Stručnjak	Tačnost	F_1 ocjena	Lokalna tačnost
DRIVE	Stručnjak 1	94.0149%	0.7661	0.7775
DRIVE	Stručnjak 2	94.4946%	0.7803	0.7910
STARE	Stručnjak 1	93.5962%	0.7159	0.7628
STARE	Stručnjak 2	91.5070%	0.6813	0.7240

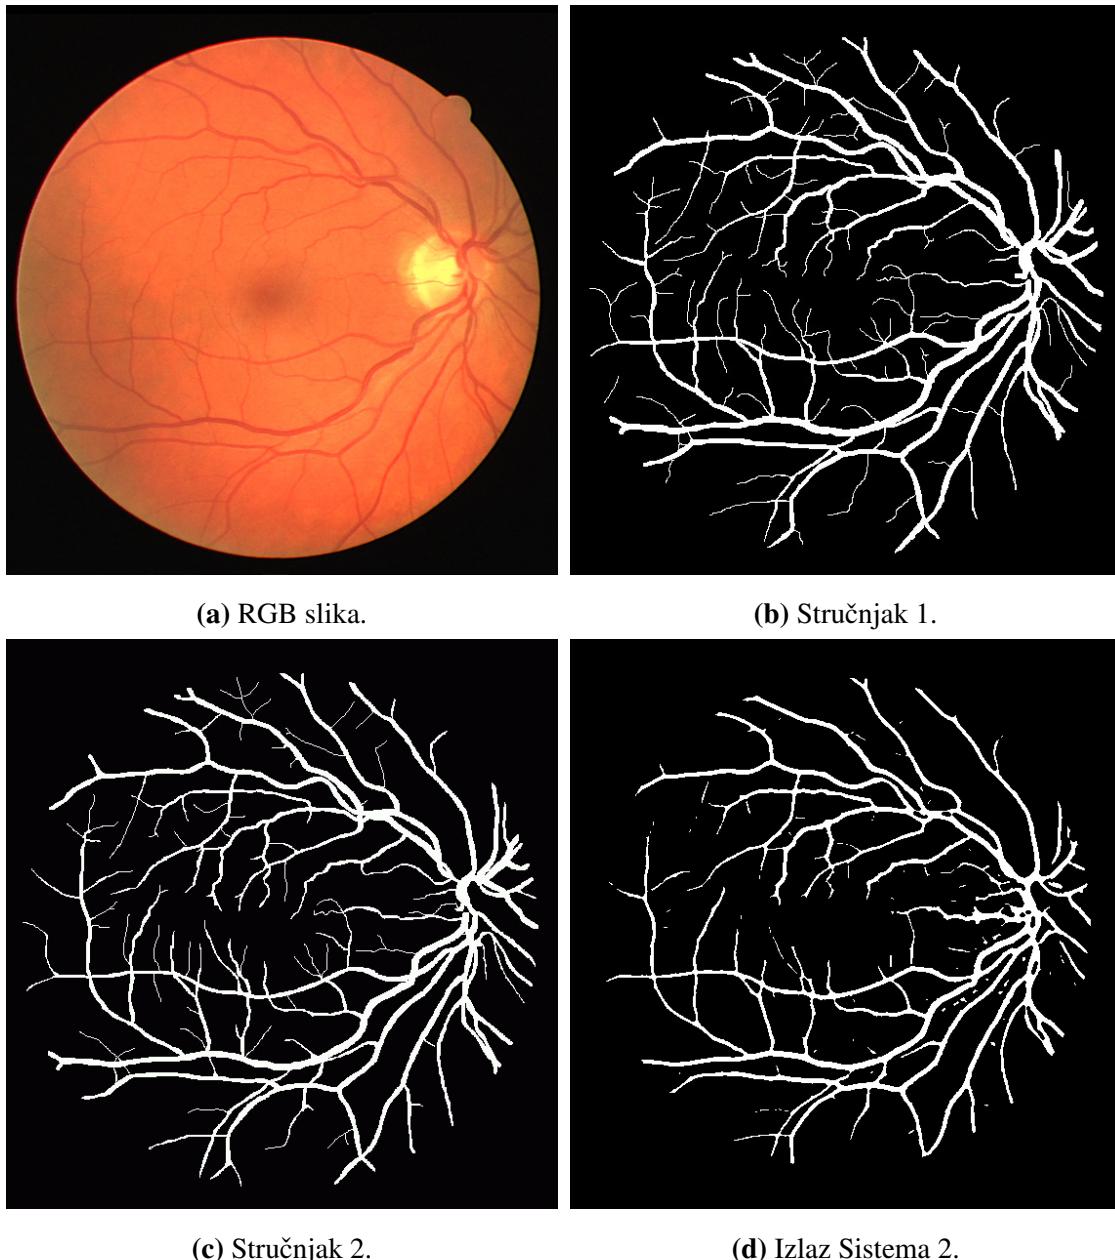
**Slika 5.44:** Tačnost sistema na DRIVE bazi.**Slika 5.45:** Tačnost sistema na STARE bazi.**Slika 5.46:** F_1 ocjena sistema na DRIVE bazi.

Slika 5.47: F_1 ocjena sistema na STARE bazi.

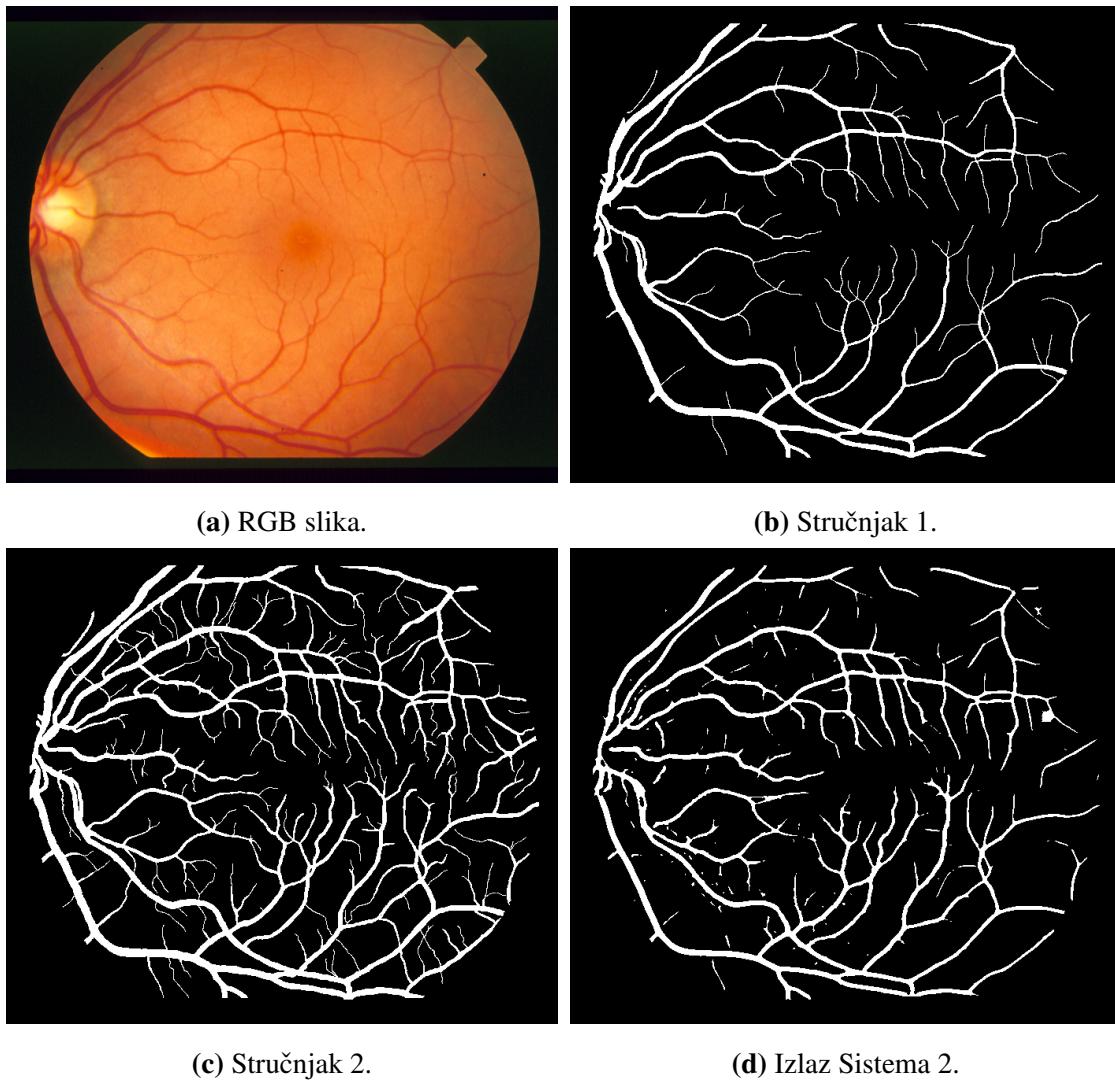
Slika 5.48: Lokalna tačnost sistema na DRIVE bazi.



Slika 5.49: Lokalna tačnost sistema na STARE bazi.



Slika 5.50: Testna slika DRIVE baze.



Slika 5.51: Testna slika STARE baze.

Da bi riješili problem oko oboljenja koja se manifestuju na mrežnjači očnog dna potrebno je da uvedemo novu karakteristiku koja će da bude četvrti ulazni podatak u neuralnu mrežu i koja će da ukazuje na razliku između piksela koji pripadaju oboljelom dijelu i ostalih piksela u mrežnjači očnog dna. Prilikom uvođenja nove karakteristike bilo bi potrebno dodati još jedan neuron u ulazni sloj, a zatim bi se mreža morala opet trenirati. U zavisnosti od tipa karakteristike koju dodajemo, možda bi bilo potrebno i povećati broj neurona u skrivenom sloju ili čak povećati broj skrivenih slojeva.

Na Slikama 5.50. i 5.51. su predstavljene RGB slike, slike odgovarajućih stručnjaka i rezultati Sistema 2 testne i trening slike DRIVE i STARE baze, respektivno.

Glava 6

Zaključak

U ovom radu su predstavljana dva sistema za segmentaciju krvnih sudova mrežnjače očnog dna. U prvom sistemu, algoritam kolonije mrava uz pomoć kombinovane karakteristike, koja je dobijena na osnovu dvije linijske karakteristike, donosi odluku o klasifikaciji piksela u jednu od dvije klase: krvni sud ili pozadina. Za testiranje sistema su korišćene testne slike DRIVE baze i trening slike STARE baze, dok su trening slike DRIVE baze korišćene za dobijanje optimalne količine isparenja feromona. Rezultati koje daje ovaj sistem se mogu porebiti sa rezultatima savremenih sistema, i to ne samo sa sistemima koji koriste algoritme bez nadgledanja, već i sa sistemima koji koriste algoritme sa nadgledanjem. Buduće aktivnosti vezane za ovaj sistem jesu dobijanje novih karakteristika vezanih za bolju klasifikaciju između piksela oboljelih oblasti i piksela krvnih sudova, kao i favorizacija najtanjih krvnih sudova, a zatim i povezivanje novodobijenih karakteristika sa kombinovanom karakteristikom. Problem piksela oboljelih oblasti bi pak možda mogao i da se riješi primjenom drugačije inicijalizacije populacije, odnosno treba pokušati da se izbjegne postavljanje mrava u piksele oboljelih oblasti.

Što se tiče drugog sistema, sistem sa neuralnom mrežom pruža još bolje performanse, što je bilo i očekivano s obzirom da se radi o algoritmu koji pripada grupi algoritama sa nadgledanjem. Za treniranje ovog sistema su korišćene trening slike DRIVE baze, dok su za testiranje korišćene testne slike iste baze i trening slike STARE baze. Glavni nedostatak sistema sa neuralnom mrežom je osjetljivost na piksele oboljelih oblasti. Iz tog razloga, buduće aktivnosti vezane za ovaj sistem jesu dobijanje nove karakteristike za rešavanje navedenog problema.

Uvođenjem novih karakteristika, koje bi pored toga što bi riješile probleme piksela

oboljelih oblasti i poboljšale performanse predloženih sistema, značajno bi mogле do-prinijele i prilikom razvoj sistema za detekciju oboljenja koje se manifestuju na mrežnjaču očnog dna. Novodobijene karakteristike u sistemima za detekciju oboljenja bi mogle da se iskoriste za segmentaciju regiona koji predstavljaju potencijalna oboljenja.

Literatura

- [1] S. Theodoridis, A. Pikrakis, K. Koutroumbas, D. Cavouras, “Introduction to pattern recognition: a matlab approach”, *Academic Press*, 2010, ISBN: 978-0123744869.
- [2] R. O. Duda, P. E. Hart, D. G. Stork, “Pattern Classification”, second edition, *Wiley-Interscience*, 2000, ISBN: 978-0471056690.
- [3] Vladimir Crnojević, “Prepoznavanje oblika za inženjere”, *FTN Izdavaštvo*, 2014 ISBN: 978-8678926488.
- [4] M.M. Fraz, P. Remagnino, A. Hoppe, B. Uyyanonvara, A.R. Rudnicka, C.G. Owen, S.A. Barman, “Blood vessel segmentation methodologies in retinal images - A survey”, *Computer Methods and Programs in Biomedicine*, vol. 108, no. 1, pp. 407-433, October 2012.
- [5] E. Ricci and R. Perfetti, “Retinal Blood Vessel Segmentation Using Line Operators and Support Vector Classification”, *IEEE Transactions On Medical Imaging*, vol. 26, no. 10, pp. 1357?1365, October 2007.
- [6] B. Zhang, L. Zhang, L. Zhang, F. Karray, “Retinal vessel extraction by matched filter with first-order derivative of Gaussian”, *Computers in biology and medicine*, vol. 40, no. 4, pp. 438-445, April 2010.
- [7] M. G. Cinsdikici, D. Aydin, “Detection of blood vessels in ophthalmoscope images using MF/ant (matched filter/ant colony) algorithm”, *Computer Methods and Programs in Biomedicine*, vol. 96, no. 2, pp. 85-95, November 2009.
- [8] V. M. Saffarzadeh, A. Osareh, and B. Shadgar. “Vessel segmentation in retinal images using multi-scale line operator and K-means clustering”, *Journal of Medical Signals and Sensors*, vol. 4, no. 2, pp.122-129, April 2014.

- [9] D. Marín, A. Aquino, M. E. Gegúndez-Arias, and J. M. Bravo, “A New Supervised Method for Blood Vessel Segmentation in Retinal Images by Using Gray-Level and Moment Invariants-Based Features”, *IEEE Transactions on Medical Imaging*, vol. 30, no. 1, pp. 146-158, January 2011.
- [10] C. A. Lupascu, D. Tegolo, E. Trucco, “FABC: Retinal Vessel Segmentation Using AdaBoost”, *IEEE Transactions on Information Technology in Biomedicine*, vol. 14, no. 5, pp. 1267-1274, September 2010.
- [11] J. V. B Soares, J. J. G. Leandro, R. M. Cesar, H. F. Jelinek, M. J. Cree, “Retinal Vessel Segmentation Using the 2-D Gabor Wavelet and Supervised Classification”, *IEEE Transactions On Medical Imaging*, vol. 25, no. 9, pp. 1214-1222, September 2006.
- [12] J. Staal, M. D. Abràmoff, M. Niemeijer, M. A. Viergever, B. V. Ginneken, “Ridge-Based Vessel Segmentation in Color Images of the Retina”, *IEEE Transactions on Medical Imaging*, vol. 23, no. 4, pp. 501-509, April 2004.
- [13] C. Sinthanayothin, J. F. Boyce, H. L. Cook, T. H. Williamson, “Automated localisation of the optic disc, fovea, and retinal blood vessels from digital colour fundus images”, *British Journal of Ophthalmology*, vol. 83, no. 8, pp. 902-910, August 1999.
- [14] B. S. Y. Lam, Y. Gao, A. W. C. Liew, “General retinal vessel segmentation using regularization-based multiconcavity modeling”, *IEEE Transactions Medical Imaging*, vol. 29, no. 7, pp. 1369-1381, Jul 2010.
- [15] B. S. Y. Lam, H. Yan, “A novel vessel segmentation algorithm for pathological retina images based on the divergence of vector fields”, *IEEE Transactions Medical Imaging*, vol. 27, no. 2, pp. 237–246, February 2008.
- [16] A. M. Mendonca, A. Campilho, “Segmentation of retinal blood vessels by combining the detection of centerlines and morphological reconstruction”, *IEEE Transactions Medical Imaging*, vol. 25, no. 9, pp. 1200-1213, Septembre 2006.
- [17] A. Fathi and A. R. Naghsh-Nilchi, “Automatic wavelet-based retinal blood vessels segmentation and vessel diameter estimation”, *Biomedical Signal Processing and Control*, vol. 8, no. 1, pp. 71-80, January 2013.

- [18] M. M. Fraza, S. A. Barmana, P. Remagnino, A. Hoppea, A. Basitb, B. Uyyanonvarac, A. R. Rudnickad, and C. G. Owend, “An approach to localize the retinal blood vessels using bit planes and centerline detection”, *Computer Methods and Programs in Biomedicine*, vol. 108, no. 2 pp. 600-616, November 2012.
- [19] A. H. Asad, A. T. Azar, and A. E. Hassaanien. “Ant colony-based system for retinal blood vessels segmentation”, *Proceedings of Seventh International Conference on Bio-Inspired Computing: Theories and Applications (BIC-TA 2012)*, Springer India, pp. 441-452, 2013.
- [20] M. D. Abramoff, M. K. Garvin, M. Sonka, “Retinal imaging and image analysis”, *IEEE reviews in biomedical engineering*, vol. 3, pp. 169-208, 2010.
- [21] M. Bajčeta, P. Sekulić, S. Đukanović, T. Popović, V. Popović-Bugarin, “Retinal blood vessels segmentation using ant colony optimization”, *Symposium Neural Networks and Applications*, ISBN: 978-1-5090-1529-0, pp. 135-141, November 2016.
- [22] M. Bajčeta, P. Sekulić, S. Đukanović, “Retinal blood vessels segmentation using neural networks and features based on line operators”, *Informacione tehnologije (IT Žabljak)*, Februar 2017.
- [23] P. Sekulić, M. Bajčeta, S. Đukanović, “Retinal blood vessels segmentation using support vector machine and modified line detector”, *Informacione tehnologije (IT Žabljak)*, Februar 2017.
- [24] C. Fernandes, V. Ramos, A. Rosa, “Self-regulated artificial ant colonies on digital image habitats”, *International Journal of Lateral Computing*, vol. 2, pp. 1–8, December 2005.
- [25] Dorigo, Marco, L. M. Gambardella. “Ant colony system: a cooperative learning approach to the traveling salesman problem”, *IEEE Transactions on evolutionary computation*, vol. 1, pp. 53-66, 1997.
- [26] W. S. McCulloch and W. Pitts, “A logical calculus of the ideas immanent in nervous activity”, *The bulletin of mathematical biophysics*, vol. 5, pp. 115-133, 1943.
- [27] Lj. Stanković, “Digital signal processing”, *Amazon.com Company*, 2015, ISBN: 978-1514179987.

- [28] G. G. Gardner, D. Keating, T. H. Williamson, A. T. Elliott, “Automatic detection of diabetic retinopathy using an artificial neural network: a screening tool”, *British journal of Ophthalmology*, vol. 80, pp. 940-944, November 1996.
- [29] Research Section, Digital Retinal Image for Vessel Extraction (DRIVE) Database. Utrecht, The Netherlands, University Medical Center Utrecht, Imaging Science Institute [Online]. Available: <http://www.isi.uu.nl/Re-search/Databases/DRIVE>
- [30] STARE ProjectWebsite. Clemson, SC, Clemson University [Online]. Available: <http://www.ces.clemson.edu/>
- [31] R. C. Gonzalez, R. E. Woods, “Digital Image Processing”, third edition, *Pearson*, 2007, ISBN: 978-0131687288.
- [32] I. Đurović, “Digitalna obrada slike”, *Univerzitet Crne Gore, Elektrotehnički fakultet Podgorica*, 2005,