



DEPARTMAN ZA POSLEDIPLOMSKE STUDIJE

DOKTORSKA DISERTACIJA

UNAPREĐENJE PROCESIRANJA
MEDICINSKIH DIGITALNIH SLIKA
POMOĆU ALGORITAMA INTELIGENCIJE ROJEVA

Mentor:

prof. dr Dejan ŽIVKOVIĆ

Kandidat:

Eva TUBA

Beograd, 2019.



GRADUATE SCHOOL

PHD THESIS

IMPROVEMENTS OF DIGITAL IMAGE PROCESSING
FOR MEDICAL APPLICATIONS
BY SWARM INTELLIGENCE ALGORITHMS

Mentor:

prof. Dejan ŽIVKOVIĆ, PhD

Candidate:

Eva TUBA

Belgrade, 2019.

Unapređenje procesiranja medicinskih digitalnih slika pomoću algoritama inteligencije rojeva

Sažetak – Medicina je jedna od nauka gde je omogućen značajan napredak pojavom digitalnih slika i obrade digitalnih slika. Računarska obrada digitalnih medicinskih slika može drastično ubrzati proces dijagnostike pri tome otkrivajući i najsitnije promene na tkivima koje nisu vidljive ljudskom oku. Obrada medicinskih slika uključuje slike generisane različitim izvorima kao što su rendgen, ultrazvuk, magnetna rezonanca, i snimljene različitim uređajima kao što su skeneri, mikroskopske slike, endoskopske kapsule i drugi. Stalni napredak u medicinskoj tehnologiji snimanja doveo je do slika visokih rezolucija, trodimenzionalnih anatomskih i fizioloških slika. Sa druge strane, ovi napreci doveli su do novih problema i izazova u procesiranju medicinskih slika. Mnogi od ovih problema predstavljaju teške optimizacione probleme za čije se rešavanje u poslednje dve decenije uspešno koriste algoritmi inspirisani prirodom, posebno algoritmi inteligencije rojeva. Da bi se ovi algoritmi primenili na probleme optimizacije u obradi medicinskih digitalnih slika, neohodno je da se posebno prilagode konkretnom problemu. Ova tema predstavlja aktivnu oblast naučnog istraživanja što se može zaključiti na osnovu velikog broja naučnih i stručnih radova, knjiga, časopisa i konferencija koji su joj posvećeni.

U ovoj tezi predstavljeno je nekoliko algoritma inteligencije rojeva i njihova primena na različite optimizacione probleme obrade medicinskih digitalnih slika. Konkretno, algoritam slepog miša, algoritam vatrometa i algoritam svica korišćeni su za registraciju slika retine, segmentaciju MRI slika mozga, detekciju krvarenja na slikama endoskopske kapsule, kompresiju slika, detekciju leukemije na mikroskopskim slikama i detekciju emfisema na CT slikama pluća. Svaki od razmatranih problema je specifičan i za njihovo rešavanje prilagođeni su algoritmi inteligencije rojeva.

Modifikovani i prilagođeni algoritmi inteligencije rojeva za primenu u obradi medicinskih digitalnih slika testirani su na standardnim skupovima test slika prikupljenim za razmatrane probleme. Poređenjem predloženih metoda unapređenja obrade medicinskih digitalnih slika pomoću algoritama inteligencije rojeva sa drugim savremenim algoritmima iz literature, pokazano je da su dobijeni bolji rezultati, što

dovodi do zaključka da je moguće pronaći bolje metode i tehnike za rešavanje problema optimizacije koji se pojavljuju prilikom analize i obrade medicinskih digitalnih slika prilagođavanjem i primenom algoritama inteligencije rojeva.

Ključne reči: medicinske digitalne slike, obrada digitalnih slika, segmentacija, registracija, kompresija, detekcija anomalija, klasifikacija, optimizacija, metaheuristike, inteligencija rojeva.

Improvements of Digital Image Processing

for Medical Applications

by Swarm Intelligence Algorithms

Abstract – Medicine is one of the sciences where significant progress was facilitated due to digital images and digital image processing. Processing medical digital images using computers can drastically speed up the diagnosis process by revealing even the slightest changes in tissues that cannot be detected with the naked eye. Medical image processing includes images generated by various sources such as X-ray, ultrasound, magnetic resonance, and acquired by different devices such as various scanners, microscopic images, endoscopic capsules and others. Continuous progress in medical imaging technology has led to high resolution images, three-dimensional anatomical and physiological images. On the other hand, this progress introduced new problems and challenges in medical image processing. Many of these problems represent hard optimization problems for which nature inspired algorithms, especially swarm intelligence algorithms, have been successfully used for more than two decades. In order to apply these algorithms for medical digital image processing optimization problems, it is necessary to modify and adjust them for a particular problem. This topic represents an active research field, which can be concluded based on large number of scientific and professional articles, books, journals and conferences dedicated to it.

In this thesis several swarm intelligence algorithms and their application to various medical digital image processing optimization problems are presented. Specifically, bat algorithm, fireworks algorithm and firefly algorithm were used for retina image registration, brain MRI segmentation, bleeding detection in endoscopic capsule images, image compression, leukemia detection in microscopic images and emphysema detection in CT lung images. Each of the considered problems is specific and swarm intelligence algorithms have been adjusted for tackling them.

Modified and customized swarm intelligence algorithms for application in the processing of medical digital images were tested on standard benchmark test images assembled for the problems under consideration. By comparing proposed methods for improving medical digital image processing using swarm intelligence algorithms with

other state-of-the-art algorithms from literature, it has been shown that better results were obtained, which leads to the conclusion that better methods and techniques for solving optimization problems that occur when analyzing and processing medical digital images can be found by adjusting and applying swarm intelligence algorithms.

Keywords: medical digital images, digital image processing, segmentation, registration, compression, detection of anomalies, classification, optimization, metaheuristics, swarm intelligence.

Slike

1	Primeri pretvaranje analognog signala u digitalni	17
2	Funkcija poređenja boja	21
3	RGB - aditivni prostor boja	22
4	RGB/CMYK prostor boja	24
5	Primer slike retine i odgovarajućih RGB komponenti (a) original, (b) crvena komponenta, (c) zelena komponenta i (d) plava komponenta .	24
6	HSI model boja	25
7	Komponente H i S iz HSI modela boja mikroskopske slike krvnih zrnaca	26
8	C_b i C_r komponente za $Y=0.5$ (YC_bC_r model boja)	27
9	CIE Lab prostor boja	27
10	Prva rendgen slika - slika šake Rendgenove žene	31
11	Rendgenska cev	32
12	Primeri rendgenskih snimaka	34
13	Primer slika sa ultrazvuka	38
14	Primer MRI i fMRI mozga	40
15	Primer MRI i CT slike mozga	40
16	Primer CT, MRI i PET slike	42
17	Primer slika prikupljenih endoskopskom kapsulom	43
18	Primer mikroskopskih slika krvi	44
19	Negativ slike	50
20	Primena γ transformacije: original slika, $\gamma=0.3$ i $\gamma=1.5$	51
21	Rezultat ekvalizacije histograma	52
22	Primena digitalnog filtera koji koristi 8-susedstvo	54
23	Primer LBP-a za 8-susedstvo	60
24	Preslikavanje podataka pomoću kernel funkcije: $(x_i, x_j) \rightarrow (x_i, x_j, x_i^2 + x_j^2)$	62
25	Sfera	67
26	Rastrigin funkcija	68
27	Klasifikacija metoda optimizacije [81]	71
28	Klasifikacija metaheuristika	73
29	Proces evolutivnih algoritama	76

30	Registracija slika retine: parametri transformacije $t_x = 60$, $t_y = 70$, $\theta = 30^\circ$	98
31	Registracija slika retine: Test par 1, $t_x = 5$, $t_y = 10$, $\theta = 20^\circ$	103
32	Registracija slika retine: Test par 2, $t_x = 3$, $t_y = 3$, $\theta = 15^\circ$	104
33	Registracija slika retine: Test par 3, $t_x = 5$, $t_y = 5$, $\theta = 9^\circ$	104
34	Test slike	109
35	Segmentacija slike Kapurovom i Otsuovom metodom	120
36	Originalne test slike	123
37	Dekompresovane slike standardnom Q_{10} kvantizacionom tabelom (levo) i tabelom Q_{10_opt} (desno) dobijenu BBFWA (fitnes funkcija je MSE)	124
38	Dekompresovane slike standardnom Q_{20} kvantizacionom tabelom (levo) i tabelom Q_{20_opt} (desno) dobijenu BBFWA (fitnes funkcija je MSE)	126
39	Primer CE slika sa krvarenjem	127
40	(a) Segmentacija CE slika koristeći samo prosečnu zasićenost, (b) ground truth	130
41	Segmentacija predloženom metodom: (a) CE slika, (b) ground truth i (c) rezultujuća segmentacija	132
42	Primer slika belih krvnih zrnaca iz ALL-IDB2 baze (a-b) normalna and (c-d) ćelija leukemije	134
43	Komponente HSI modela boja mikroskopskih slika krvnih zrnaca: normalnih (levo) i ćelije leukemije (desno)	135
44	(a),(d) ćelije, (b),(e) jezgra i (c),(f) citoplazma	136
45	CT pluća	140
46	Primer zdravog tkiva i različitih emfizema	140
47	Primer uzoraka iz korišćene baze: normalno tkivo i emfizme	142

Tabele

1	Procenjene vrednosti t_x, t_y i θ sa različitim brojem iteracija i slikama u punoj rezoluciji, $t_x = 60, t_y = 70, \theta = 30^\circ, t_x, t_y \in [-100, 100], \theta \in [-50, 50]$	99
2	Procenjene vrednosti t_x, t_y i θ sa različitim brojem iteracija i slikama u punoj rezoluciji, $t_x = 60, t_y = 70, \theta = 30^\circ, t_x, t_y \in [t_{x,y} - 2, t_{x,y} + 2], \theta \in [\theta - 2, \theta + 2]$	99
3	Procenjene vrednosti t_x, t_y i θ u različitim rezolucijama, $t_x = 60, t_y = 70, \theta = 30^\circ, t_x, t_y \in [-100, 100], \theta \in [-50, 50]$	101
4	Poređenje rezultata dobijenih predloženim algoritmom vatrometa i metodom iz literature [109]	104
5	Poređenje rezultata dobijenih predloženim algoritmom vatrometa i metodom iz literature [109]	105
6	Trešhold vrednosti i vrednosti funkcije cilja dobijene iscrpnom pretragom za Kapurovu metodu	110
7	Poređenje prosečne vrednosti funkcija cilja i standardne devijacije Kapurove metode dobijenih predloženih algoritom slepog miša sa rezultatima iz [68] i [57]	112
8	Poređenje trešhold vrednosti dobijenih korišćenjem Kapurove metode i predloženog algoritma slepog miša sa rezultatima iz [68] i [57]	113
9	Trešhold vrednosti i vrednosti funkcije cilja dobijene iscrpnom pretragom za Otsuovu metodu	115
10	Poređenje prosečne vrednosti funkcija cilja i standardne devijacije Otsuove metode dobijenih predloženih algoritom slepog miša sa rezultatima iz [68]	116
11	Poređenje trešhold vrednosti dobijenih korišćenjem Otsuove metode i predloženog algoritma slepog miša sa rezultatima iz [68]	117
12	Poređenje PSNR vrednosti	118
13	Kvantizacionim tabela Q_{10} (levo) and Q_{10_opt} optimizovana BBFWA (desno)	123
14	Kvantizacionim tabela Q_{20} (levo) and Q_{20_opt} optimizovana BBFWA (desno)	125

15	Poređenje različitih mera sličnosti dobijenih preporučenim kvantizaci-	
	onim tabelama i tabelama dobijenim predloženim BBFWA	126
16	Poređenje karakteristika za različite klase regiona	130
17	Poređenje vrednosti DSC dobijene predloženim algoritmom (Grid-	
	SVM) i metodom iz [20]	131
18	Poređenje ME dobijene predloženom metodom i metodom iz [20] (AGC)	131
19	Poređenje rezultata iz rada [59] i predložene BBFWA metode	138
20	Matrica konfuzije za klasifikaciju uzoraka iz korišćene baze predlože-	
	nom metodom (tačnosti prikazane u %)	142
21	Poređenje rezultata predloženog algoritma sa metodama predloženim	
	u [74] i [102]	143

Algoritmi

1	Opšti pseudo kod evolutivnih algoritama	76
2	Pseudo kod algoritma slepog miša	82
3	Generisanje vođene varnice za X_i [53]	86
4	Vođeni algoritam vatrometa [53]	86
5	Maksimalno pojednostavljen algoritam vatrometa, BBFWA [54] . . .	87
6	Algoritam svica, FA [103]	89
7	Pseudo kod brain storm optimizacionog algoritma	91
8	Predloženi algoritam za detekciju krvarenja na CE slikama	128

Sadržaj

Slike	5
Tabele	7
1 Uvod	12
2 Digitalne slike	15
2.1 Digitalizacija	16
2.2 Zapis digitalne slike u računar u	18
2.3 Modeli boja	19
3 Medicinske digitalne slike	29
3.1 Rendgenski snimci	30
3.2 Ultrazvučne slike	35
3.3 Magnetna rezonanca (MRI)	38
3.4 Pozitron emisiona tomografija (PET)	41
3.5 Endoskopska kapsula	42
3.6 Medicinske slike snimljene mikroskopom	43
4 Procesiranje medicinskih digitalnih slika	45
4.1 Spacijalni i frekventni domen	47
4.2 Manipulacija osvetljenjem slike	49
4.3 Segmentacija	52
4.4 Frekventne komponente i kompresija	63
5 Teški optimizacioni problemi	65
5.1 Matematička formulacija problema globalne optimizacije	68
6 Metaheuristike	71
7 Algoritmi inspirisani prirodom	75
7.1 Evolutivni algoritmi	76
7.2 Algoritmi inteligencije rojeva	77
7.2.1 Optimizacija rojem čestica	79

7.2.2	Algoritam slepog miša	80
7.2.3	Algoritam vatrometa	82
7.2.4	Algoritam svica	88
7.2.5	Brain storm optimizacioni algoritam	89
8	Prilagođavanje algoritama inteligencije rojeva problemima analize i obrade medicinskih digitalnih slika	93
8.1	Registracija slika retine	93
8.2	Segmentacija MRI slika mozga	105
8.3	Frekventne komponente i kompresija slika	120
8.4	Detekcija krvarenja na EC slikama	126
8.5	Detekcija leukemije na mikroskopskim slikama	133
8.6	Detekcija bolesti pluća na CT slikama	140
9	Zaključak	145
10	Literatura	147

1 Uvod

Uticaj i značaj digitalnih slika na moderno društvo, nauku, tehnologiju i umetnost su ogromni. Obrada slike je postala kritična komponenta u savremenoj nauci i tehnologiji tako da bi mnoge zadatke bilo praktično nemoguće rešiti bez nje. Obrada digitalnih slika je istinski interdisciplinarna nauka koja se zasniva na sinergijskom razvoju mnogih disciplina. Koristi se u medicinskoj obradi slika, mikroskopiji, astronomiji, računarskoj viziji, geologiji i mnogim drugim oblastima.

Metode kompjuterske analize i dijagnostike postavili su medicinsko snimanje na mesto jednog od najvažnijih pod-polja obrade digitalnih slika. Značajan napredak u razumevanju razvijanja bolesti i sposobnosti pružanja kvalitetne zdravstvene zaštite je između ostalog i rezultat napretka u oblasti obrade medicinskih digitalnih slika, odnosno razvijanjem metoda automatizovane analize istih. Ovi zadaci nisu ni malo jednostavni ali su od izuzetne važnosti, što je razlog intenzivnog istraživanja.

Mnogi problemi koji se javljaju prilikom obrade medicinskih digitalnih slika predstavljaju teške optimizacione probleme za koje ne postoje deterministički metodi koje pronalaze optimalno rešenje u razumnom vremenskom periodu. Za rešavanje ovakvih problema koriste se neke stohastičke metode poput algoritama inteligencije rojeva. Ovi algoritmi se preko dve decenije uspešno primenjuju na probleme optimizacije iz raznih oblasti kao što su ekonomija, industrija, biologija, itd.

Za rešavanja problema optimizacije u oblasti obrade medicinskih digitalnih slika kao što su registracija slika, segmentacija, kompresija, neophodno je prilagoditi i po potrebi modifikovati algoritme inteligencije rojeva.

U ovom radu razmatra se prilagođenje optimizacionih algoritama inteligencije rojeva za poboljšanje obrade medicinskih digitalnih slika. Rad se sastoji iz uvoda, zaključka, spiska literature i sedam poglavlja.

Nakon uvoda, u drugom poglavlju opisan je proces digitalizacije, prednosti digitalnih medija sa posebnim akcentom na digitalim slikama i njihovoj primeni u različitim naučnim oblastima. Prikazan je način zapisa digitalne slike u računarstvu i modeli boja koji se koriste.

U trećem poglavlju je dat pregled medicinskih digitalnih slika. Opisani su načini dobijanja slika iz različitih izvora, a zatim su dati primeri primene i potrebe za svakom od njih.

Četvrto poglavlje je posvećeno algoritmima obrade digitalnih slika. Opisani su različiti domeni slika u kojima se može vršiti obrada, a zatim su opisani neki od algoritama za manipulaciju osvetljenjem, segmentaciju i kompresiju. U ovom poglavlju je prikazana raznovrsnost ovih algoritama, njihova namena, potencijalne modifikacije i kombinacije. Posebno su naglašeni problemi optimizacije koje se javljaju prilikom nekih od obrada.

U petom poglavlju je definisan problem optimizacije, teški optimizacioni problemi i izazovi koji se pojavljuju prilikom njihovog rešavanja.

U šestom poglavlju su dati pojmovi heuristike i metaheuristike i neki od pokušaja klasifikacije heuristika. Dalje su prikazane teorijske osnove i koncepti metaheuristika.

U sedmom poglavlju su opisani optimizacioni algoritmi inspirisani prirodom. Dat je kratak opisa evolutivnih algoritama dok je glavni deo ovog poglavlja posvećen algoritmima inteligencije rojeva. Opisano je nekoliko algoritama inteligencije rojeva sa naglaskom na onima koji su korišćenji u istraživanjima prikazanim u osmom poglavlju.

U osmom poglavlju su izloženi glavni rezultati ove disertacije. Razmatrano je šest različitih problema optimizacije u domenu obrade medicinskih digitalnih slika. Za svaki od problema je prilagođen ili modifikovan neki od algoritama inteligencije rojeva. Sve predložene metode su detaljno opisane i prikazane kao i baze slika koje su korišćene. Nakon eksperimentalnih rezultata koji uključuju i komparativnu analizu sa postojećim metodama iz literature, diskutovano je o postignutim rezultatima i potencijalnim budućim istraživanjima.

Razmatrano je šest metoda obrade medicinskih digitalnih slika uz pomoć algoritama inteligencije rojeva: registracija slika retine, segmentacija MRI slika mozga, kompresija medicinskih slika, detekcija krvarenja digestivnog trakta na slikama dobijenih od endoskopske kapsule, klasifikacija leukocita sa mikroskopskih slika u cilju detekcije leukemije i detekcija lezija na CT slikama pluća.

Rezultati istraživanja prezentovanih u ovoj disertaciji su prihvaćeni od međunarodne naučne zajednice i objavljeni su u sledećim radovima:

1. Tuba, E., Tuba, M., & Dolicanin, E. (2017). Adjusted fireworks algorithm applied to retinal image registration. *Studies in Informatics and Control*, 26(1), 33–42 (M23)

2. Tuba, E., Jovanovic, R., Beko, M., Tallon-Ballesteros, A. J., & Tuba, M. (2018). Bare Bones Fireworks Algorithm for Medical Image Compression. *Lecture Notes in Computer Science (LNCS): Intelligent Data Engineering and Automated Learning*. 262–270. Springer
3. Tuba, E., Tuba, M., & Simian, D. (2017). Support Vector Machine Optimized by Firefly Algorithm for Emphysema Classification in Lung Tissue CT Images, 25th International Conference in Central Europe on Computer Graphics, Visualization and Computer Vision, *Computer Science Research Notes* 2702, 159–166
4. Tuba, E., Tuba, M., & Jovanovic, R. (2017). An algorithm for automated segmentation for bleeding detection in endoscopic images. In *IEEE International Joint Conference on Neural Networks, 2017* (pp. 4579–4586). (Anchorage, Alaska)
5. Tuba, E., Strumberger, I., Bacanin, N., Zivkovic, D. & Tuba, M. (2019). Acute Lymphoblastic Leukemia Cell Detection in Microscopic Digital Images Based on Shape and Texture Features. In *10th International Conference on Swarm Intelligence (ICSI'2019)*, (pp. 1-8). (Chiang Mai, Thailand)
6. Tuba, E., Capor Hrosik, R., Zivkovic, D. & Tuba, M. (2019). Multilevel Thresholding for Segmentation of Brain Magnetic Resonance Images Using Bat Algorithm, submitted to *Studies in Informatics and Control*

2 Digitalne slike

Vid predstavlja jedno od najnaprednijih čula čoveka tako da nije iznenađujuće što slike imaju jednu od vrlo važnih uloga u ljudskom životu. U današnje vreme su digitalne slike široko rasprostranjene. Pored brojnih digitalnih slika koje se svakog dana naprave mobilnim telefonima ili digitalnim fotoaparatom za ličnu upotrebu, digitalne slike postale su i sastavni deo mnogih naučnih oblasti. Bitno je naglasiti da ljudi vide samo ograničeni deo elektromagnetnog spektra a da različiti uređaji mogu zabeležiti slike iz skoro celog elektromagnetnog spektra, od gama zraka sve do radio talasa. Relativno jednostavno pribavljanje i obrađivanje digitalnih slika kao i sveukupan napredak tehnologije su omogućili upotrebu istih u najrazličitijim naučnim granama gde ranije nije delovalo da mogu imati ikakvu svrhu.

Jedan od primera gde se ne bi očekivala upotreba digitalnih slika bila bi upotreba u agrokulturi. Danas se digitalne slike, satelitske slike plantaža ili slike snimljene dronom, uveliko koriste za različite svrhe. Jedna od primena je blagovremeno detektovanje i prepoznavanje bolesti na biljkama [5, 83]. Obrada digitalnih slika plantaža se takođe koristi za utvrđivanje kvaliteta zemljišta [39], kontrolisanja sistema navodnjavanja [64, 35], procene napretka useva [11] i slično. Svi ovi poslovi bez pomoći digitalnih slika iziskuju mnogo vremena uz ogromne troškove. Običi veliku plantažu i proveriti svaku biljku i komad zemljišta je praktično nemoguće, dok korišćenjem aplikacije koja će prikupiti slike plantaže i automatski ih obraditi, to ne zahteva puno vremena a rezultati su često precizniji i detaljniji od procene eksperta. Jedan od razloga ovakvih rezultata je brzina rada računara u odnosu na čoveka, a drugi razlog je mogućnost pronalaženja detalja pomoću kompjuterske obrade slika koji mogu promaći ili su nevidljivi ljudskom oku.

Digitalne slike se takođe koriste u istraživanju okeana. Zahvaljujući napretku tehnologije, moguće je snimiti delove okeana koji nisu pristupačni čoveku. I u ovom slučaju, analiza slika od strane eksperta može da potraje jako dugo i pojedini detalji mogu da promaknu, dok automatskom primenom adekvatnih algoritama obrade digitalnih slika se mogu brzo identifikovati vrste, pronaći jedinstvene karakteristike istih, uočiti razlike i slično. Softveri za obradu slika u oblasti istraživanja okeana uključuju i brojanje pojedinačnih organizama kako bi se pronašla prostorna gustina i obilje [70], sa digitalnih slika se može proceniti hemijski sastav na morskom dnu

bez potrebe za fizičkim uzorkom [41]. Ovaj tip nedestruktivnog uzorkovanja je posebno važan za druge istraživače u oblastima kao što je podvodna arheologija za identifikaciju artefakata i kreiranje foto mozaika čitavog lokaliteta [55].

Digitalne slike su danas sastvane deo automatske kontrole saobraćaja. Kamere se postavljaju na visok stub, odakle se jasno mogu videti pojedine saobraćajne trake ili raskrsnice. One se koriste za snimanje slika (ili video zapisa) saobraćaja tako da se u svakom trenutku može proveriti stanje u posmatranoj ulici. Softveri za automatsku kontrolu saobraćaja imaju efikasne algoritme obrade digitalnih slika tako da se vozila mogu detektovati pod različitim otežanim uslovima (magla, mrak, itd.). U zavisnosti od gustine saobraćaja, softver će kontrolisati semafore, otvarati odnosno zatvarati trake za pojedini smer kretanja i slično [96, 80].

Još jedna praktična upotreba digitalnih slika je nadgledanje određenih oblasti sa različitim ciljevima. Na primer, algoritmi obrade digitalnih slika se koriste za detekciju vatre što je od velike važnosti u šumskim krajevima gde druge metode detekcije vatre nisu moguće ili nisu dovoljno efikasne [10, 94].

Jedna od oblasti koja je koristila i analogne slike ali je pojavom digitalnih slika postigla neverovatan napredak je medicina. Medicinske digitalne slike su od izuzetnog značaja i njihova automatska obrada je drastično ubrzala i poboljšala proces dijagnostike i praćenja oporavka pacijenta. U ovom radu će biti obrađeni neki od algoritama obrade medicinskih slika te će o ovome biti više u daljem tekstu.


2.1 Digitalizacija

Iako se reč *digitalno* često koristi u svakodnevnom životu njena definicija nije tako opšte poznata. Analogno, odnosno kontinualno ili neprekidno predstavlja suprotan pojam, pa je digitalno diskretno ili prekidno.

U najširem smislu, signal je bilo koja veličina koja se može meriti i koja nosi neku informaciju o vremenski promenljivom fizičkom procesu. Primeri signala su zvuk, pritisak, slika, i slično. Signali se mogu predstaviti kao funkcije jedne ili više nezavisnih promenljivih, odnosno postoje jednodimenzionalni ili višedimenzionalni signali. Kod jednodimenzionalnih signala se najčešće podrazumeva da je nezavisna promenljiva vreme dok kod dvodimenzionalnih signala, nezavisne varijable su često prostorne koordinate. U slučaju trodimenzionalnih signala često se radi o tri prostorne

promenljive ili dve prostorne i jednoj vremenskoj promenljivoj.

Digitalizacija je predstavljanje analognog signala nizom brojeva koji predstavljaju izmerene vrednosti tog signala u sukcesivnim vremenskim momentima i to uglavnom ekvidistantnim. Digitalni signal je predstavljen dugačkim nizom brojeva. Taj niz je vrlo nečitljiv čoveku i postavlja se pitanje kvaliteta tog signala. U zavisnosti od vremena koje protekne od jednog do drugog merenja, analogni signal može biti interpretiran na različite načine što je ilustrovano na slici 1.



Slika 1: Primeri pretvaranje analognog signala u digitalni

Ukoliko se uzme veći vremenski razmak između dva merenja, značajna količina podataka može biti izgubljena. Sa druge strane, uzimanje vrlo malog vremenskog perioda dovodi do ogromne količine podataka. Odgovor na pitanje koliko često bi trebalo meriti signal daje Najkvist-Šenonova teorema (engl. Nyquist-Shannon sampling theorem) koja tvrdi da je potrebno da frekvencija sampliranja signala bude dva puta veća od najveće frekvencije analognog signala i tom slučaju se dobija potpuno veran prikaz tog signala u digitalnom zapisu.

Ova teorema daje kvalitativnu i kvantitativnu informaciju o odnosu digitalnog i analognog signala. Kvalitativna informacija je da će signal biti potpuno verno prikazan dok kvantitativna informacija govori o broju merenja po periodu koje je potrebno da bi se to postiglo.

Kada se radi sa digitalnim signalima, uvek je moguće napraviti identičnu kopiju jednostavnim prepisivanjem niza brojeva koji predstavljaju taj signal. Posledica ove prednosti dovodi do još jedne, a to je neograničeni rok trajanja. Treća prednost digitalizacije je drastično lakša manipulacija i obrada. Za razliku od analognih filtera koji su se sastojali od otpornika, kondenzatora, induktora i slično, digitalni filteri su matematičke formule (funkcije) koje se primenjuju na niz brojeva koji predstavlja

signal. Pronalaskom inverzne funkcije (ukoliko postoji) i njenom primenom na izmenjen digitalni signal se može ponovo dobiti originalni signal. Jedino što je zaustavljalo proces digitalizacije je bio problem čuvanja ogromne količine podataka koji je rešen tek pojavom kompakt diska (engl. compact disk, CD)

2.2 Zapis digitalne slike u računaru

Slika je definisana pravougaonikom gde su se proporcije ovog pravougaonika menjale kroz istoriju. Početo je sa razmerom 4:3 da bi se kasnije u filmskoj industriji koristila 16:9. U današnje vreme te razmere variraju usled različitih uređaja i potreba, od mobilnih telefona, tableta do monitora i televizora.

Na slikama je zanemarena treća dimenzija pošto ljudi uglavnom nemaju problem sa percepcijom treće dimenzije na slikama odnosno iz iskustva mogu da zaključe šta je ispred a šta iza na dvodimenzionalnoj slici. Treća dimenzija se vidi zahvaljujući parnosti organa vida odnosno očiju. Danas su sve popularniji 3D televizori koji u suštini proizvode dve odvojene pokretne slike i šalju jednu od njih levom oku gledaoca, a drugu desnom.

Da bi se od analogne slike dobila digitalna potrebno je izvršiti dvostruku diskretizaciju. Prva se odnosi na deljenje pravougaonika po vertikali i horizontali čime se dobija matrica manjih pravougaonika koji su najčešće istih stranica, odnosno uglavnom su to kvadrati. Ovi kvadrati se nazivaju elementi slike ili pikseli (engl. picture elements, pixels), što znači da se digitalne slike sastoje od piksela organizovanih u matrici. Rezolucija slike određena je dimenzijom ove matrice piksela gde je širina slike broj kolona, a visina slike je broj redova.

Matematički, digitalna slika je matrica piksela sa M kolona i N redova. Da bi se referisao određeni piksel unutar matrice slike, definišu se njegove koordinate x i y . Koordinatni sistem matrica slika definiše da se x povećava s leva na desno, a y koordinata se povećava od vrha ka dnu. U poređenju sa normalnom matematičkom konvencijom, koordinatni početak je u gornjem levom uglu i y koordinata je okrenuta. Ovakva organizacija koordinata proizlazi iz prvobitne definicije digitalnih slika u terminima skeniranja elektronskog snopa televizora. Snop skenira s leva na desno i od vrha do dna. Osim ovog istorijskog razloga, ne postoji druga svrha ove inverzije y koordinata. Trebalo bi napomenuti da veličina slike ne predstavlja veličinu realnog

prikaza slike.

Svaki piksel ima sopstvenu vrednost intenziteta svetlosti ili osvetljenost. Po tipu intenziteta koji se koristi za svaki piksel razlikuju se tipovi slika. Crno-bele slike imaju intenzitet od najtamnijeg sivog (crnog) do najsvetlijeg sivog (belog). Naziv *crno-bele slike* ne odgovara potpuno onome što slika prikazuje, ali se taj termin koristio i za analogne slike. Za stvarno crno-bele slike, slike sa samo dve nijanse na njoj, se obično koristi termin binarna slika. S druge strane, kod slika u boji, pikseli imaju intenzitete od najtamnije do najsvetlije boje, najčešće definisani kombinacijom nekih boja. Kojim sve bojama je definisan piksel zavisi od modela boja koji se koristi (na primer, u RGB modelu se svaki piksel definiše nijansom crvene, zelene i plave). Različite smeše intenziteta boja daju sliku u boji.

Pored tipa intenziteta svakog piksela, opseg vrednosti intenziteta takođe varira. Granice intenziteta u digitalnim slikama su definisane brojem bitova korišćenih za zapis svakog piksela. 8-bitni raspon intenziteta ima 256 mogućih vrednosti, od 0 do 255. Ovo predstavlja drugu diskretizaciju. Analogni signali su definisani nad realnim brojevima dok se za potrebe digitalizacije izmerene vrednosti zaokružuju.

Prelaskom na digitalne slike dobijene su sve prednosti digitalizacije. Međutim, potrebno je naglasiti da su brojne naučne oblasti doživele pravu revoluciju zahvaljujući upotrebi digitalnih slika i velikim napretkom tehnologije. Obrada digitalnih slika danas predstavlja zasebnu naučnu oblast i postoji ogroman broj interdisciplinarnih istraživanja. Neke od oblasti koje su se značajno razvile i napredovale uključuju astronomiju, biologiju, agrikulturu i druge. Automatska obrada i analiza medicinskih slika je u potpunosti revolucionizovala proces dijagnostike i lečenja. Kako su problemi obrade medicinskih slika vrlo značajna pitanja, posebna pažnja naučnika je usmerena ka rešavanju ovih problema.

2.3 Modeli boja

Za procesiranje digitalnih slika potrebno je definisati kako je slika predstavljena u računaru, posebno slike u boji. Do sada je slika definisana kao matrica celih brojeva, jedna u slučaju crno-belih slika ili više njih za slike u boji (svaka za po jednu komponentu boje). Kako su aplikacije koje koriste digitalne slike veoma različite, od nadgledanja nepristupačnih širokih predela, analiziranja astronomskih

slika, vasijskih objekata sa jedne strane do sitnih stvari poput krvnih zrnaca i ćelija sa druge strane, do upotrebe u forenzici, bezbednosti, itd., a dodatno su izvori dobijanja tih slika veoma različiti, pogotovo kada se govori o medicinskim slikama, nije moguće koristiti jedinstven model boja koji jednako dobro opisuje slike za sve navedene primere. Tokom poslednjih decenija definisani su različiti modeli boja koji su pronašli svoju praktičnu primenu u brojnim aplikacijama. Trebalo bi naglasiti da se iz jednog modela mogu izraziti i svi ostali modeli, razlika je u tome koje su karakteristike slike više ili manje naglašene u kom modelu. U nastavku će biti definisani osnovni modeli boja kao i njihove primene u procesiranju medicinskih slika.


Da bi se predstavila boja na digitalnom uređaju, prvo je bilo potrebno definisati šta je to boja. Ovo pitanje je daleko komplikovanije nego što može izgledati na prvi pogled. Za ljude, boja je vizuelna karakteristika koja je duboko povezana sa emocionalnim, estetskim i kulturnim aspektima ljudskog iskustva. U kontekstu fizike, boja je samo prikladan način za opisivanje različitih talasnih dužina elektromagnetnog zračenja. U čisto fizičkom smislu boja ne postoji. Postoje svetlosni talasi, a talasna dužina ove svetlosti može da varira, ali boja - zelena, plava, crvena i ostale su samo fikcija koju stvara ljudski mozak.

Ovo naglašava poteškoće u prevodenju boja u digitalno područje. Boja je subjektivni fenomen odnosno talasne dužine su objektivne stvari, ali vizuelni izgled povezan sa određenom talasnom dužinom uspostavlja biološki sistem koji prima i tumači elektromagnetno zračenje. Budući da računare, robote i senzorske sisteme obično koriste ljude, cilj digitalne obrade boja je stvaranje informacija i slika koje su u skladu sa ljudskim vidom. Zbog ovoga su se u procesu digitalizacije iskoristile neke od karakteristika ljudskog oka.

Jedna od prvih matematičkih definicija prostora boja je napravljena od strane Međunarodne komisije za osvetljenje, Commission Internationale de l'Eclairage, CIE koja se bavi tehničkim, naučnim i kulturološkim aspektima osvetljenja, svetla, boje i prostora boja. Ova definicija boje je nazvana CIE RGB i definisan je 1931. godine na osnovu ispitivanja sprovedenih krajem 1920-ih godina od strane naučnika Vilijama Virhta (engl. William David Wright) i Džona Guilda (engl. John Guild). Ispitivanja su bila osmišljena na osnovu karakteristike ljudskog oka u kojem postoje tri vrste

receptora koji su osetljivi na boju (čepići, engl. cones) i oni su osetljivi na boje oko talasnih dužina koje predstavljaju crvenu, plavu i zelenu boju. Mozak može da sabere neku količinu od svake od tri boje i da ih vidi kao novu boju. Pravljenje relativno jednostavnog sistema boja je moguć zahvaljujući ovoj osobini. Ukoliko ne bi bilo ovih receptora, predstavljanje boje u računaru bi bio veoma težak zadatak.

Ideja eksperimenta je bila da se napravi funkcija poređenja boja (engl. color matching function) odnosno da se odredi količina crvene, zelene i plave svetlosti čijim se mešanjem dobijaju osećaji određene boje. Za referentne boje uzete su: crvena boja sa talasnom dužinu 700nm, zelena sa 546.1nm i plava 435.8nm. Od učesnika ekperimenta je traženo da pronađu podudaranje određene boje sa bojom koja je dobijena kao linearna kombinacija primarnih boja. Na osnovu podudaranja koja su ispitanici odredili dobijena je i funkcija poređenja boja prikazana na slici 2. Na x -osi su prikazane talasne dužine, a po y osi inteziteti primarnih boja.



Slika 2: *Funkcija poređenja boja*

Kao posledica organizacije eksperimenta, pojedine talasne dužine su bile predstavljene negativnim vrednostima komponenti, pa je funkcija preslikana u teorijske vrednosti x , y i z koje predstavljaju redom crvenu, zelenu i plavu komponentu:


$$\begin{aligned}
 x(\gamma) &= 0.49r(\gamma) + 0.31g(\gamma) + 0.20b(\gamma) \\
 y(\gamma) &= 0.17697r(\gamma) + 0.81240g(\gamma) + 0.01063b(\gamma) \\
 z(\gamma) &= 0.00r(\gamma) + 0.01g(\gamma) + 0.99b(\gamma)
 \end{aligned} \tag{1}$$

CIE XYZ model je zasnovan na percepciji boje posmatrača a izveden je iz CIE RGB modela. Ovaj model može da predstavi sve boje vidljive ljudskim okom i osnova je za sve ostale izvedene modele definisane od strane CIE. Komponente X i Z se koriste za opisivanje boja dok je Y komponenta iskorišćena za definisanje inteziteta boje. Bela boja je definisana jednakim vrednostima ove tri komponente. Definicija komponenti preko CIE RGB je data sledećom formulom:

$$\begin{aligned} X &= 0.4124 * R + 0.3576 * G + 0.1805 * B \\ Y &= -0.2126 * R + 0.7152 * G + 0.7220 * B \\ Z &= 0.0193 * R + 0.1192 * G + 0.9505 * B \end{aligned} \quad (2)$$

Većina modela boja koji se danas koriste su ili orijentisane ka hardveru (monitori, štampači, itd.) ili ka aplikacijama.

RGB i CMY modeli su neki od najpoznatijih modela boja pogodnih za hardversku implementaciju. Kod RGB modela svaki piksel je opisan intezitetom crevene, zelene i plave boje (engl. **R**ed, **G**reen, **B**lue). Ovaj sistem se koristi za prikazivanje boja na monitorima, televizorima, mobilnim telefonima, itd. Boja se dobija emitovanjem svetlosti pa ovo predstavlja aditivni model što znači da se inteziteti osnovnih boja sabiraju kako bi se dobio spektar. Pomešani makisamlni inteziteti sve tri komponente daju belu boju, dok potpuno odsustvo boja predstavlja crnu boju (slika 3).



Slika 3: RGB - aditivni prostor boja

Na neki način suprotan model RGB modelu koji koriste autoemitujući uređaji je CMY model boja koji opisuje spektar boja uređaja koji nemaju svoje svetlo već se boje dobijaju tako što apsorbuju i reflektuju određene količine svetlosti. Tipičan primer gde se suptraktivni CMY model boja koristi je štampač. Naziv CMY ponovo potiče od početnih slova primarnih boja u ovom sistemu (engl. **C**yan, **M**agenta, **Y**ellow). Kako se ovaj model boja koristi za štampače, a mešanjem sve tri komponente maksimalnim intezitetom se dobijala *zamućena* crna boja, ona je dodata kao posebna komponenta. Usled ovoga je i ime modela prošireno na CMYK, gde je slovo K dobijeno od *blacK*. Boje u suptraktivnom modelu se dobijaju oduzimanjem RGB komponenti, cijan se dobija oduzimanjem crvene boje, magenta oduzimanjem zelene, a žuta oduzimanjem plave boje:


$$\begin{bmatrix} & R & G & B \\ C & 0 & 1 & 1 \\ M & 1 & 0 & 1 \\ Y & 1 & 1 & 0 \\ K & 1 & 1 & 1 \end{bmatrix}$$

Veza između RGB i CMYK modela je data sledećom formulom (pod pretpostavkom da su opsezi inteziteta normirani):

$$\begin{bmatrix} C \\ M \\ Y \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} - \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (3)$$

Na slici 4 je RGB modeli prikazani u Dekartovom koordinatnom sistemu gde je crvena boja na x-osa, zelena na y-osa, a plava na z-osi. Tačka (0, 0, 0) predstavlja crnu boju dok je u nasuprot nje bela boja koja se dobija mešanjem maksimalnih inteziteta sve tri komponente (u ovom primeru su inteziteti u intervalu [0, 1]).

RGB model se često koristi u aplikacijama obrade medicinskih digitalnim slika. Na slici 5 je prikazana slika retine i njena dekompozicija na komponente RGB modela. Sa slike je jasno vidljivo da su vene, fini detalji, najbolje prikazani zelenom komponentom te se dalje obrade obično vrše nad njom. Ovo je čest slučaj sa medicinskim slikama gde zeleni kanal obično ima najbolji kontrast. Takođe se često



Slika 4: RGB/CMYK prostor boja

uzimaju i takozvane slike oslobođene crvene boje (engl. red-free image) [26].




(a)



(b)



(c)



(d)

Slika 5: Primer slike retine i odgovarajućih RGB komponenti (a) original, (b) crvena komponenta, (c) zelena komponenta i (d) plava komponenta

Jedan od načina definisanja boje koji je blizak ljudskoj percepciji boja je HSI model. Kao što bi čovek opisao neku boju njenom bojom, zasićenošću i intezitetom tako i ovaj model opisuje boje. HSI naziv potiče od početnih slova komponenti: **H**ue - boja, **S**aturation - zasićenost i **I**ntensity odnosno intezitet. Prva komponenta opisuje boje u zavisnosti od talasne dužine svetlosti, druga komponenta meri čistoću boje odnosno koliko ima ahromatske (sive) komponente. Treća komponenta predstavlja količinu svetlosti i odgovara monohromatskoj komponenti.

Veza između HSI i RGB modela boja je data sledećim formulama:

$$H = \begin{cases} \theta & \text{if } B \leq G, \\ 360 - \theta & \text{if } B > G, \end{cases}$$


gde je θ definisano sa:

$$\theta = \cos^{-1} \left\{ \frac{\frac{1}{2}[(R - G) + (R - B)]}{[(R - G)^2 + (R - B)(G - B)]^{1/2}} \right\}$$

$$S = 1 - \frac{3}{R + G + B} [\min(R, G, B)] \quad (4)$$

$$I = \frac{1}{3}(R + G + B) \quad (5)$$


Na slici 6 je shematski prikazan HSI model boja.



Slika 6: *HSI model boja*

HSI model boja se takođe neretko koristi za obradu medicinskih slika. Jedna od primena je segmentacija krvnih zrnaca snimljenih pod mikroskopom. Na slici 7 su prikazane H i S komponenta, odnosno boja i zasićenost. Sa bojom je jasno izdvojena cela krvna ćelija dok slika komponente S prikazuje samo jezgro. Kombinovanjem ove dve komponente moguće je izdvojiti glavne delove ćelije.

Još jedan dosta korišćen model za opisivanje boje na digitalnim slikama je YC_bC_r model. Ovde je Y luminentna komponenta i predstavlja osvetljenost boje (engl. brightness). Ljudsko oko je osetljivije na ovu komponentu u odnosu na preostale dve



Slika 7: Komponente H i S iz HSI modela boja mikroskopske slike krvnih zrnaca

komponente, C_b i C_r koje definišu boju. Komponenta C_b je plava komponenta dok je C_r crvena komponenta. Preciznije se može reći da je C_b plava komponenta u odnosu na zelenu komponentu dok je C_r crvena komponenta u odnosu na zelenu.

Veza između YC_bC_r i RGB modela je definisana na sledeći način:

$$\begin{aligned} Y &= 0.299 * R + 0.587 * G + 0.114 * B \\ C_b &= -0.168 * R - 0.331 * G + 0.500 * B \\ C_r &= 0.500 * R - 0.418 * G - 0.081 * B \end{aligned} \quad (6)$$

Od komponenti YC_bC_r modela se mogu dobiti RGB komponente koristeći sledeće formule:


$$R = Y + 1.402(C_r - 128) \quad (7)$$

$$G = Y - 0.34414(C_b - 128) - 0.71414(C_r - 128) \quad (8)$$

$$B = Y + 1.772(C_b - 128) \quad (9)$$


Na slici 8 je prikazano prostiranje boja kada je Y komponenta jednaka 0.5.

Jedan od CIE modela boja često korišćen za obradu digitalnih slika, posebno medicinskih, je CIE Lab model koji je definisan 1976. godine. Ovaj model definiše boju pomoću dve hromatske i jedne ahromatske komponente. Komponenta L , ahromatska komponenta, označava osvetljenost dok su a i b komponente boje. Komponenta a opisuje boje od zelene ka crvenoj dok je b komponenta namenjena za opisivanje boja od plave ka žutoj. Parovi boja su odabrani da odgovaraju teoriji suprotnih procesa



Slika 8: C_b i C_r komponente za $Y=0.5$ (YC_bC_r model boja)

(engl. opponent color theory) kojom je opisano kako ljudsko oko vidi boje. Grafički prikaz CIE Lab modela je dat na slici 9.



Slika 9: CIE Lab prostor boja

CIE Lab model se izvodi iz CIE XYZ modela sledećom formulom:

$$\begin{aligned}
 L &= 116 * f\left(\frac{Y}{Y_n}\right) - 16 \\
 a &= 500 * \left(f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right)\right) \\
 b &= 200 * \left(f\left(\frac{Y}{Y_n}\right) - f\left(\frac{Z}{Z_n}\right)\right)
 \end{aligned} \tag{10}$$

gde je funkcija f definisana kao:

$$f(t) = \begin{cases} \sqrt[3]{t} & \text{if } t > \beta^3, \\ \frac{t}{3\beta^2} + \frac{4}{29} & \text{otherwise} \end{cases}$$

gde je $\beta = \frac{6}{29}$. X_n , Y_n i Z_n su konstante sa sledećim vrednostima: $X_n=95.047$, $Y_n=100.000$ i $Z_n=108.883$.

CIE Lab model boja se često kombinuje sa drugim modelima boja za obradu medicinskih slika. Takođe predstavlja jedan od modela boja koji se može vrlo efikasno upotrebiti za detekciju kože i pojedine metode za obradu slika kože u medicinske svrhe, koriste CIE Lab model [100].

3 Medicinske digitalne slike

Digitalne slike su u mnogim naukama donele revolucionalne promene između ostalog zbog mogućnosti upotrebe digitalne obrade i digitalnih filtera koji su u odnosu na analogne mnogo moćniji. Medicina je nauka koja je koristila slike dobijene od različitih izvora i pre digitalnog doba, ali je značajno profitirala od pojave digitalnih slika. Poslednjih nekoliko decenija postižu se veliki napreci u medicini upravo zahvaljujući brojnim tehnikama medicinskog snimanja i digitalnoj obradi dobijenih slika. Medicinsko snimanje predstavlja neinvazivnu metodu koja omogućuje detaljan pogled na unutrašnjost tela i vizuelni pregled funkcija unutrašnjih organa i tkiva.

Značaj korišćenja digitalnih slika u medicini se može ilustrovati na primeru rendgena koji je dosta star. X-zraci su otkriveni 1895. godine i nekoliko meseci kasnije, 1896. godine, počeli su da se upotrebljavaju u medicini [76]. Ovo je predstavljalo veliku prekretnicu u medicini gde je postalo moguće videti unutrašnjost ljudskog tela. Danas se rendgenski snimci koriste za dijagnostiku raznih bolesti kao i za praćenje uspešnosti prepisanih terapija. Iako rendgenski snimci mogu da snime unutrašnjost tela, da bi ta slika imala ikakav značaj mora postojati način da se ta slika analizira i da se izvedu zaključci, odnosno da se postavi dijagnoza. Pre pojave digitalnih slika, analiza rendgenskih snimaka je bila komplikovan zadatak. Zavisila je od sposobnosti eksperta da uoči anomaliju na slici, što je dalje zavisilo od mnogih faktora poput osvetljenja, kvaliteta vida stručnjaka, iskustva, itd. Kod digitalnih slika, to je potpuno drugačija procedura jer se u deliću sekunde mogu primeniti mnogi digitalni filteri, moguća je automatizovana analiza i otkrivanje anomalija koje nisu vidljive golim okom, itd. Ovo je takođe slučaj i kod drugih vrste medicinskih slika koje su uvedene kasnije.

Danas postoje mnogobrojne tehnike medicinskih snimanja kako bi se dobilo više informacija o ljudskom telu i koje su veoma značajne za ranu dijagnostiku bolesti. Neke od tehnika dobijanja medicinskih slika su: X-zraci, kompjuterska tomografija (CT), magnetna rezonanca (MRI), foton emisiona kompjuterizovana tomografija (SPECT), pozitron emisiona tomografija (PET), ultrazvuk, endoskopija, fluoroskopija, itd.

Uz pomoć računara, može se manipulirati dobijenim medicinskim digitalnim slikama da bi se otkrili dijagnostički detalji brže ali i preciznije što je od izuzetne

važnosti za postavljanje ispravne i blagovremene dijagnoze. Kompjuterska obrada mora biti izvedena tako da se sačuvaju i unaprede medicinski značajni detalji na slici. Neki od najčešćih zadataka kompjuterske obrade medicinskih digitalnih slika su segmentacija, analiza regiona od interesa i prepoznavanje anomalija.

Za medicinske slike je specifično da pri obradi nije bitna ljudska percepcija kvaliteta i lepote slike, već je bitno da na slici bude vidljivo i naglašeno ono što je od medicinskog značaja. Medicinske slike predstavljaju širok spektar slika te je njihovoj obradi potrebno posvetiti posebnu pažnju. Medicinski instrumenti koji se koriste prilikom snimanja detektuju različite signale pomoću kojih proizvode sliku u cilju dobijanja informacija o fiziološkim procesima i organima u ljudskom telu. Dobijene slike mogu biti različitog kvaliteta, prikazivati različite organe te je potrebno posvetiti posebnu pažnju svakom tipu slike i anomaliji koja se može detektovati i prilagoditi algoritam obrade slike prema tome.

U nastavku će biti opisane karakteristike i svrhe nekih od najbitnijih medicinskih slika.

3.1 Rendgenski snimci

X-zraci su tip elektromagnetnog zračenja koji su verovatno najpoznatiji po svojoj sposobnosti da vide kroz telo osobe i otkriju slike kostiju i organa u telu. Napredak u tehnologiji doveo je do snažnijih i fokusiranih rendgenskih zraka, što je rezultiralo većom primenom kako u medicini tako i u drugim oblastima.

X-zrake je 1895. godine otkrio Vilhelm Konrad Røntgen (engl. Wilhelm Conrad Roentgen), profesor na Univerzitetu Würzburg u Nemačkoj. Veruje se da je prva rendgen slika, slika šake njegove žene (Slika 10). Za ovo otkriće, Røntgen je za ovo otkriće dobio Nobelovu nagradu za fiziku 1901. godine.

X-zraci su grubo klasifikovani u meke i tvrde rendgenske zrake. Meki rendgenski zraci imaju relativno kratke talasne dužine od oko 10 nanometara, i tako padaju u opseg elektromagnetnog (EM) spektra između ultraljubičastog (UV) i gama-zračenja. Tvrđi rendgenski zraci imaju talasne dužine od oko 100 pikometara. Ovi elektromagnetni talasi zauzimaju istu oblast EM spektra kao gama-zraci.

X-zraci i gama zraci se razlikuju jedino po tome kako nastaju, odnosu po izvoru porekla. X-zrake nastaju ubrzavanjem elektrona, dok je gama zračenje proizvod



Slika 10: Prva rendgen slika - slika šake Rendgenove žene


radioaktivnih atoma. X-zraci i gama zraci se ne mogu videti, osetiti, niti čuti. Oni nemaju naboja i nemaju masu i stoga nisu pod uticajem električnih i magnetnih polja i obično putuju pravim linijama. Međutim, oni se mogu prelomiti na način sličan kao svetlo. I rendgenski i gama zraci se mogu okarakterisati frekvencijom, talasnom dužinom i brzinom. Međutim, ponekad oni mogu delovati kao čestice pošto se pojavljuju kao mali *paketi* energije i nazivaju se *fotoni*. Elektromagnetno zračenje je takođe opisano u smislu struje fotona (čestica bez masa) koje se kreću u talasnom uzorku brzinom svetlosti. Svaki foton sadrži određenu količinu (ili snop) energije, a celokupno elektromagnetno zračenje se sastoji od tih fotona. Jedina razlika između različitih vrsta elektromagnetnog zračenja je količina energije koja se nalazi u fotonima. Zbog njihove kratke talasne dužine imaju više energije da prolaze kroz materiju nego druge forme energije u elektromagnetnom spektru. Kako prolaze kroz materiju, one se raspršuju i apsorbuju, a stepen prodiranja zavisi od vrste materije i energije zraka.

Neka od svojstva X-zraka i gama zraka su:

- Ljudska čula ih ne mogu detektovati (ne mogu se videti, čuti, osetiti, itd.).
- Putuju pravim linijama brzinom svetlosti.
- Njihove staze se ne menjaju električnim ili magnetnim poljima.
- Oni prolaze kroz materiju dok ne dođu do susreta sa nekom atomskom česticom.

- Stepen prodiranja zraka zavisi od njihove energije kao i od materije kroz koju prolaze.
- Njihova energija je dovoljna da ionizuju materiju, oštete ili čak unište žive ćelije.

Rendgensko zračenje se obično dobija unutar rendgenske cevi. Ova cev predstavlja vakuumsku cev gde je sa jedne strane anoda a sa druge katoda zajedno sa žarnom niti. Katoda ima visok napon u odnosu na anodu. Kada se žarna nit užari usled protoka električne struje, katoda će izbaciti elektrone. Ti elektroni se ubrzavaju unutar električnog polja između anode i katode i udaraju u anodu koja se vrti da bi imala što bolje hlađenje a takođe je i napravljena od materijala koji je otporan na visoke temperature. Prilikom ovog procesa oko 99% energije elektrona se pretvara u toplotu, dok preostala energija odlazi u obliku ionizovanog zračenja. Ovo zračenje izlazi kroz otvor na rendgenskoj cevi pod određenim uglom. Rendgenska cev je prikazana na slici 11.



Slika 11: *Rendgenska cev*

Radiografija se malo promenila od prvih dana njene upotrebe. I dalje se snima slika senki na filmu koristeći slične procedure i procese koje su tehničari koristili krajem 1800-ih. Danas se međutim mogu generisati i slike višeg kvaliteta. Elektronika i kompjuteri omogućavaju tehničarima da sada digitalno snimaju slike. Upotreba "radiografije bez filma" omogućava snimanje digitalne slike, njenu digitalnu obradu, i arhiviranje slike koja se neće vremenom pogoršati odnosno iskorišćene su sve prednosti digitalizacije. Tehnološki napredak pružio je industriji manju, lakšu i veoma prenosivu opremu koja proizvodi visokokvalitetne rendgenske zrake.

Iako se proces malo promenio, tehnologija je evoluirala i omogućila da se radiografija široko koristi u brojnim oblastima inspekcije. Upotreba radiografije u industriji se proširila sa ispitivanja varova i odlivka, na radiografski pregled predmeta

kao što su vazdušni jastuci i konzervirani prehrambeni proizvodi. Radiografija je pronašla upotrebu u metalurškim sistemima, sistemima za identifikaciju i sigurnost na aerodromima i drugim objektima. Inspekcija gama zracima se takođe značajno promenila od otkrića radijuma. Današnji izotopi su daleko jači i nude tehničaru širok spektar energetskih nivoa, pa se može efikasno prodirati kroz veoma debele materijale ili, ako se izabre izotop manjeg napona se može koristiti za pregled plastike i materijala male gustine. Danas pored medicine gama zraci imaju široku primenu u oblastima kao što su petrohemija, livenje, zavarivanje i vazduhoplovstvo.


U medicini se rendgensko snimanje koristi za stvaranje slika unutrašnjosti tela. Slike prikazuju delove tela u različitim nijansama sive boje. To je zato što različita tkiva apsorbuju različite količine zračenja. Kalcijum u kostima najviše apsorbuje rendgenske zrake, tako da kosti izgledaju belo. Masti i druga meka tkiva apsorbuju manje i izgledaju sivo. Najmanje upija vazduh, tako da, na primer, pluća izgledaju crno.

Najpoznatija upotreba rendgenskih zraka je provera lomljenih kostiju, ali se rendgenski snimci koriste i na druge načine. Na primer, na rendgenski snimcima grudnog koša se može uočiti upala pluća. Mamogrami koriste rendgenske snimke da bi pronašli rak dojke. Rendgenska tehnologija se koristi za ispitivanje mnogih delova tela kao što su:


- **Kosti i zubi**

- Frakture i infekcije. U većini slučajeva, frakture i infekcije u kostima i zubima jasno se pojavljuju na rendgenskim snimcima.
- Artritis. Rendgenski snimci zglobova mogu otkriti znakove artritisa. Rendgenski snimci koji se uzimaju tokom godina mogu pomoći lekaru da utvrdi da li se artritis pogoršava.
- Stanje zuba. Stomatolozi koriste rendgenske snimke kako bi fotografisali zube i vilice.
- Osteoporoza. Specijalne vrste rendgenskih testova mogu da mere gustinu kostiju.
- Rak kostiju. X-zraci mogu otkriti tumore kostiju.

- **Grudi**



(a) Upala levog plućnog krila (b) Karcinom dojke (c) Uvećano srce i krvni sudovi u plućima i srcu



(d) Digestivni trakt (e) Strani objekat u telu

Slika 12: *Primeri rendgenskih snimaka*

- Infekcije pluća. Dokazi upale pluća, tuberkuloze ili raka pluća mogu se pojaviti na rendgenskim snimcima grudi (slika 12(a) [7]).
- Karcinom dojke. Mamografija je poseban tip rendgenskog testa koji se koristi za ispitivanje tkiva dojke (slika 12(b) [79]).
- Uvećano srce. Ovaj znak zatajenja srca jasno se pojavljuje na rendgenskim snimcima (slika 12(c) [38]).
- Blokirane krvne sudove. Promene u protoku krvi u plućima i srcu mogu se videti na rendgenskim snimcima grudi.

- Stomak

- Problemi sa digestivnim traktom. Barijum, kontrastno sredstvo, može pomoći u otkrivanju problema u probavnom sistemu (slika 12(d) [16]).
- Strani objekti u telu. Deca često progutaju nešto poput ključa ili novčića, a rendgen može pokazati lokaciju tog objekta (slika 12(e) [67]).

Kompjuterizovana tomografija (engl. computed tomography, CT) i fluoroskopija koriste jonizujuće zračenje za generisanje slika tela kao i radiografija (konvencionalni

rendgen, uključujući mamografiju). Jonizirajuće zračenje je oblik zračenja koji ima dovoljno energije da potencijalno prouzrokuje oštećenje DNK i može podići rizik dobijanja raka. CT i fluoroskopija funkcionišu na istom osnovnom principu kao i radiografija: rendgenski zrak se prenosi kroz telo gde unutrašnje strukture deo rendgenskih zraka apsorbiraju, a preostali rendgenski uzorak se prenosi na detektor (npr. film ili ekran računara) za snimanje. Ove vrste medicinskih slika se razlikuju po svrsi:

- **Radiografija** - jedna slika se snima za kasniju procenu.
- **Fluoroskopija** - na monitoru je prikazana kontinuirana rendgenska slika, koja omogućava praćenje u realnom vremenu. Koristi se tokom određenih medicinskih procedura ili se prati prolaz kontrastnog sredstva (boje) kroz telo kako bi se uočile anomalije. Fluoroskopija potencijalno proizvodi visoku dozu zračenja, posebno prilikom složenih postupka poput postavljanje stenta ili drugih uređaja unutar tela pošto ti postupci traju duži vremenski period.
- **CT** - mnogi rendgenski snimci se snimaju dok se detektor kreće oko tela pacijenta. Računar rekonstruiše sve pojedinačne slike u slike preseka unutrašnjih organa i tkiva. CT pregled uključuje veću dozu zračenja od konvencionalne radiografije, jer se CT slika rekonstruiše iz mnogih pojedinačnih rendgenskih projekcija.

Otkriće rendgenskih zraka i pronalazak CT-a predstavljali su značajan napredak u medicini. Rendgenski snimci su priznati kao vredno medicinsko sredstvo za širok raspon pregleda i procedura. Koriste se za:

- neinvazivnu i bezbolnu dijagnostiku i za praćenje uspešnosti terapije;
- podršku planiranju medicinskog i hirurškog lečenja;
- usmeravanje medicinskog osoblja dok ubacuju katetere, stente ili druge uređaje u telo, tretiraju tumore, uklanjaju krvne ugruške ili druge blokade.

3.2 Ultrazvučne slike

Ultrazvuk (UZ) se koristi u medicini za prikaz unutrašnjosti ljudskog tela preko 50 godina. Prvi rad objavljen na ovu temu je napisao austrijski neurolog Kral Teodor

Dusik (engl. Karl Theodore Dussik) 1942. godine kada je koristio ultrazvuk za ispitivanje mozga. Engleski lekar Džon Vajld (engl. John Wild) se smatra začetnikom medicinskog ultrazvuka. On je početkom 1950-ih godina upotrebio ultrazvuk da posmatra mokraćnu bešiku sa ciljem da izmeri debljinu njenih zidova. Godine 1963. kreće serijska proizvodnja dijagnostičkih ultrazvučnih aparata. Od 1967. godine razvija se dopler sonografija.

Tokom više od pola veka, ultrazvučna dijagnostika je napredovala u raznim pravcima. Pre svega proširena je oblast primene. Napredak ultrazvučne dijagnostike se kreće u dve krajnosti, minimalizacija i portabilnost aparata na jednoj strani, a maksimizacija prodornosti i preciznosti sa druge strane.

Danas ultrazvuk predstavlja jednu od najčešće korišćenih tehnika snimanja u medicini. On je prenosiv, bez rizika od radijacije i relativno jeftin u poređenju sa drugim metodama snimanja, kao što su radiografija i magnetna rezonanca. Slike se mogu dobiti u realnom vremenu, pa na taj način pružaju trenutne vizuelne smernice za mnoge interventne procedure kao što je na primer davanje vođenja raznih punkcija.


Savremeni medicinski UZ uglavnom koristi impulsnu eho metodu sa prikazom osvetljenja (B-mod, prethodio mu je A-mod sa jednodimenzionalnom slikom). Kao i u slučaju radiografije, osnovni principi snimanja u B-modu su danas isti kao i pre nekoliko decenija. Ovo podrazumeva prenos malih impulsa ultrazvučnog eha iz sonde u telo. Kako ultrazvučni talasi prodiru u tkiva različitih akustičnih impedancija, neki se reflektuju nazad na sondu (eho signali), a neki nastavljaju da prodiru dublje. Eho signali koji se vraćaju iz mnogih sekvencijalnih koplanarnih impulsa obrađuju se i kombinuju da bi se generisala slika. Dakle, ultrazvučni pretvarač radi i kao zvučnik (generisanje zvučnih talasa) i kao mikrofoni (prima zvučne talase).

Ultrazvuk se danas koristi za dijagnostikovanje i praćenje anomalija i bolesti gotovo svih organa. Ultrazvučne slike se koriste u:


- Kardiologiji (ehokardiografija)
- Endokrinologiji
- Gastroenterologiji
- Ginekologiji

- Za dijagnostikovanje i kontrolisanje stanja uključujući endometriozu, adenomiozu, ciste jajnika i lezije
- Za dijagnostikovanje pojedinih vrsta raka
- itd.
- Za obavljanje intervencija (npr. vođenje injekcija, isisavanje tečnosti, itd.)
- Analizu mekih thiva, kože, mišića, nerava, itd.
- Akušerstvu
 - Za određivanje lokacije fetusa,
 - Proveravanje položaja placente u odnosu na cerviks
 - Procena rasta fetusa
 - Provera postojanja velikih fizičkih abnormalnosti
 - Proveravanje kretanja fetusa i otkucaja srca
 - Određivanje pola deteta
 - itd.
- Vaskularni ultrazvuk
- Urologiji
- Snimanje grudi
 - Da bi se odredila priroda abnormalnosti tkiva
 - Za ultrazvučno vođenu biopsiju
 - itd.

Na slici 13 su dati primeri ultrazvučnih slika bubrega, tiroidne žlezde i fetusa [17].



(a) Bubreg



(b) Tiroidna žlezda



(c) Fetus

Slika 13: *Primer slika sa ultrazvuka*

3.3 Magnetna rezonanca (MRI)

Magnetna rezonanca (engl. magnetic resonance imaging, MRI) predstavlja neinvazivnu tehniku snimanja koja proizvodi trodimenzionalne detaljne anatomske slike bez upotrebe štetnog zračenja. Kao i druge medicinske slike, MRI se koristi za otkrivanje bolesti, dijagnozu i praćenje tretmana. Zasniva se na sofisticiranoj tehnologiji koja pokreće i detektuje promenu pravca rotacione osovine protona pronađenih u vodi koja se nalazi u tkivima.

Za generisanje MRI slika se koristi snažno magnetno polje i radio talasi pri čemu se mogu snimiti delovi tela koji se ne mogu videti sa rendgenskim snimcima, CT skenovima ili ultrazvukom. Na MRI slikama se na primer, može videti unutrašnjost zglobova, hrskavice, ligamenata, mišića i tetiva, što ga čini korisnim za otkrivanje


različitih sportskih povreda. MRI se takođe koristi za ispitivanje unutrašnjih telesnih struktura i dijagnostikovanje raznih poremećaja, kao što su moždani udar, tumori, aneurizme, povrede kičmene moždine, multipla skleroza, problemi oka ili unutrašnjeg uha, itd. Takođe se široko koristi u istraživanju strukture i funkcije mozga.

Glavni sastojak ljudskog tela je voda. Molekuli vode sadrže vodikovo jezgro (protone), koja se poravnavaju u magnetnom polju. MRI skener primenjuje jako magnetno polje (oko 0,2T do 3T, ili otprilike hiljadu puta jači od tipičnog magneta za frižider), koji poravnava protonske spinove. Skener takođe proizvodi struju koja stvara promenljivo magnetno polje. Protoni apsorbuju energiju iz magnetnog polja i okreću svoje spinove. Kada je polje isključeno, protoni se postepeno vraćaju u svoj normalni spin, proces nazvan precesija. Proces povratka proizvodi radio signal koji se može meriti prijemnicima u skeneru i pretvoriti u sliku.

Mogu se razlikovati difuzni MRI i funkcionalni MRI. Difuzni MRI, koji postoji oko 20 godina, pokazuje promene u intenzitetu signala do kojeg dolazi zbog pomeranja molekula vode izazvan difuzijom. Srednja dužina putanje molekula vodonika po jedinici vremena predstavlja signal tkiva odnosno tečnosti iz organizma. Ova putanja se zasniva na translacionom kretanju pri kojem dolazi do gubitka signala. Brzina kretanja molekula vodonika je proporcionalna sa gubitkom signala na slici. Kako bi se snimila što detaljnija slika moguće je kontrolisati pravac i količinu difuzije promenom jačine i pravca gradijenta magnetnog polja koje se koristi. Određeni procesi bolesti kao što je moždani udar ili tumor mogu ograničiti difuziju.

Funkcionalni MRI se koristi za vizuelizaciju funkcionalne aktivnosti u mozgu. Funkcionalni MRI, ili fMRI, meri promene u protoku krvi u različitim delovima mozga. Koristi se za posmatranje moždanih struktura i za određivanje delova mozga koji obavljaju kritične funkcije. Funkcionalni MRI se takođe može koristiti za procenu oštećenja nastalih povredom glave ili usled Alchajmerove bolesti. fMRI je posebno koristan u neurologiji i predstavlja revolucioniran način proučavanja mozga. Na slici 14 je prikazan primer difuzne i funkcionalne MRI slike mozga [42].

Što se tiče odnosa MRI slika sa ostalim medicinskim slikama, može se reći da su najbližnje CT slikama. CT slike se generalno češće koriste od MRI najviše zbog cene. MRI slike se, međutim, smatraju superiornijim u pogledu detalja slike. Najznačajnija razlika je u tome što CT skenovi koriste jonizujuće zrake dok MRI ne.




Slika 14: *Primer MRI i fMRI mozga*

MRI rizici uključuju:

- moguće reakcije metala na magnete (problem kod pacijenata sa veštačkim zglobovima, pejsmejkerima, itd.),
- glasni zvukovi iz mašine mogu uzrokovati probleme sa sluhom,
- povećanje telesne temperature tokom dugih MRI snimanja,
- klaustrofobija.

I MRI i CT skenovi mogu da vide unutrašnje strukture tela. Međutim, CT skeniranje je brže i može pružiti slike tkiva, organa i skeletne strukture. MRI slike su dosta detaljnije u prikazu unutrašnjosti ljudskog organizma. Primer MRI i CT snimka mozga je prikazan na slici 15 [42].



Slika 15: *Primer MRI i CT slike mozga*

3.4 Pozitron emisiona tomografija (PET)

Pozitronska emisiona tomografija, koja se naziva i PET slike ili PET skeniranje, je vrsta snimanja nuklearne medicine. Nuklearna medicina je grana medicinskog snimanja koja koristi male količine radioaktivnog materijala za postavljanje dijagnoze i utvrđivanje stadijuma bolesti kao i za lečenja pojedinih bolesti, uključujući mnoge vrste raka, bolesti srca, gastrointestinalnih, endokrinih, neuroloških poremećaja i drugih. Postupci snimanja nuklearne medicine su neinvazivni i, sa izuzetkom intravenskih injekcija, obično su bezbolni medicinski testovi koji pomažu lekarima da dijagnostikuju i procene zdravstveno stanje.

Budući da su postupci nuklearne medicine u stanju da odrede molekularnu aktivnost unutar tela, oni nude mogućnost detekcije bolesti u najranijim fazama kao i neposrednu procenu odgovora pacijenta na terapijske intervencije.


Ova metoda generisanja slika koriste radioaktivne materijale koji se zovu radiofarmaceutici ili radioterapeuti. Radioterapeuti su molekuli vezani sa malom količinom radioaktivnog materijala koji se može detektovati na PET skeniranju. Oni su dizajnirani da se akumuliraju u kanceroznim tumorima ili regijama upale. Takođe se mogu vezati za specifične proteine u telu. Najčešće korišćeni radioaktivni marker je F-18 fluorodeoksiglukoz, ili FDG, molekul sličan glukozu. Čelije raka mogu apsorbovati glukozu većom brzinom od zdravih ćelija. Ova razlika u brzini apsorpcije se može videti na PET skeniranju, i to omogućava lekaru da identifikuje bolest pre nego što se može videti na drugim testovima snimanja.

U zavisnosti od vrste pregleda nuklearne medicine, radioaktivni talog se ubrizgava u telo, proguta ili udiše kao gas, i na kraju se akumulira u organu ili području tela koje se ispituje. Radioaktivne emisije otkrivaju specijalne kamere ili uređaji za snimanje koji proizvode slike i pružaju molekularne informacije.

U mnogim centrima, slike nuklearne medicine se mogu preklapati sa kompjuterizovanom tomografijom ili magnetnom rezonancom da bi se proizveli posebni pogledi, praksa poznata kao fuzija slika ili multimodalna registracija. Ovi pogledi omogućavaju da se informacije sa dva različita izvora povežu i interpretiraju na jednoj slici, što dovodi do preciznijih informacija i tačnijih dijagnoza. Pored toga, proizvođači sada izrađuju CT sa pojedinačnom fotonskom emisijom/CT (engl. single photon emission computed tomography/computed tomography, SPECT/CT) i uređaje sa

PET/CT koje su u mogućnosti da obavljaju oba snimanja u isto vreme. Iako se pojavila se tehnologija snimanja PET/MRI ona još uvek nije dostupna.

PET skeniranje meri važne funkcije tela, kao što su protok krvi, korišćenje kiseonika i metabolizam šećera (glukoze), kako bi pomogli lekarima da procene koliko dobro funkcionišu organi i tkiva. Danas se gotovo sva PET skeniranja obavljaju na instrumentima koji su kombinovani PET i CT skeneri obzirom da CT snimanje pruža odlične anatomske informacije. Kombinovani PET/CT skeneri generišu slike koje ukazuju na anatomsku lokaciju abnormalne metaboličke aktivnosti u telu. Na slici 16 su prikazane PET, MRI i CT slike kao i njihove kombinacije [8].




Slika 16: Primer CT, MRI i PET slike

3.5 Endoskopska kapsula

Pored korišćenja digitalnih slika u medicini, razvoj tehnologije je drugi bitan faktor zaslužan za razvoj dijagnostike. Jedan od primera je endoskopska kapsula (engl. capsule endoscopy, CE) što je naziv procedure u kojoj se mala bežična kamera koristi za prikupljanje velikog broja slika celog digestivnog trakta. Ova procedura se komercijalno koristi u poslednje dve decenije. Ova procedura zahteva da pacijent proguta bežičnu kameru koja se nalazi u kapsuli veličine vitamina. Fotoaparat snima hiljade slika tokom putovanja kroz probavni trakt. Ove slike se šalju uređaju koji pacijent nosi na pojasu.

CE omogućava lekarima da vide delove digestivnog trakta koji su sakriveni ili teško pristupačni tradicionalnim endoskopskim postupcima. Ova procedura proizvodi ogromnu količinu slika, obično oko 50.000 i sve te slike je potrebno ispitati. Analiza lekara može trajati više sati, čak i dana i podložna je ljudskoj grešci. S druge strane, takva velika količina podataka je dobar primer kada se mogu primeniti algoritmi obrade digitalnih slika i mašinskog učenja.

Primer slika prikupljenih ovom procedurom je prikazan na slici 17.



Slika 17: *Primer slika prikupljenih endoskopskom kapsulom*

3.6 Medicinske slike snimljene mikroskopom


Mikroskopske slike se koriste u medicini za hematološke, patološke i histološke preglede. Patohistolozi pregledaju slojeve tkiva ispod mikroskopa i ispituju ih na različitim nivoima povećanja, kao što je $10\times$, $40\times$, $100\times$, itd. kako bi analizirali jezgra ćelija, detektovali normalne i abnormalne delove tkiva.

Obično preparati pregledani pomoću mikroskopa mogu biti [21]:

- Uzorak krvi, kako bi se razaznale komponente krvi, kao što je broj crvenih i belih krvnih zrnaca, broj trombocita, itd.

- Uzorak tela, za proučavanje normalne strukture ili zdrave ćelije (histološke) i abnormalne strukture ili obolele/mrtve ćelije (patološke),
- Unutrašnji uzorak, uzet biopsijom (uzimanje uzorka određenog tkiva za lekarski pregled bolesti ili uočavanje nenormalanog rasta) uzoraka iz bubrega, jetre i slično.

Potpuna automatizacija u medicinskoj mikroskopiji postignuta je u oblasti kliničkog određivanja broja različitih leukocita. Proizvodnja ovih mikroskopa počela je 1974. godine. Oni analiziraju slike belih i crvenih krvnih zrnaca i trombocita po stopi od oko 100.000 slajdova dnevno. Ovo predstavlja neverovatnu automatsku analizu slika i prepoznavanje uzoraka, oko 5 milijardi slika godišnje. Može se reći da ovo predstavlja veliki uspeh u primeni računarstva, obrade digitalnih slika i mašinskog učenja u medicini. U drugim oblastima, kao što su citologija i citogenetika, automatizovana obrada je još u fazi istraživanja. Na slici 18 je prikazan primer mikroskopske slike krvi [51].



Slika 18: *Primer mikroskopskih slika krvi*

4 Procesiranje medicinskih digitalnih slika

Obrada ili procesiranje digitalnih slika podrazumeva primenu određenih matematičkih formula na matricu brojeva sa ciljem da se dobije poboljšana slika, gde je kvalitet relativan pojam i zavisi od krajnjeg cilja obrade. Drugi rezultat obrade digitalne slike mogu biti neke numeričke ili druge korisne informacije kao što su regioni od interesa. Drugim rečima, obrada digitalnih slika predstavlja vrstu obrade signala u kojoj je ulaz slika dok izlaz može biti slika ili karakteristike povezane sa ulazom. Ovo predstavlja jednu od oblasti koja svakodnevno napreduje i raste: za poznate probleme se pronalaze bolja rešenja ali se i svakodnevno definišu novi problemi koji mogu da potiču iz najrazličitijih oblasti poput agrikulture, kriminologije, robotike i slično.

Najveći značaj primene računara u obradi medicinskih slika leži u upotrebi tehnika za obradu slike za kvantitativnu analizu. Medicinske slike su pre svega vizuelne prirode, međutim, vizuelna analiza od strane ljudskog posmatrača je obično povezana sa ograničenjima uzrokovanim varijacijama i greškama među posmatračima usled umora, ometanja i ograničenog iskustva. Tumačenje medicinskih slika od strane stručnjaka zavisi od njegovog iskustva i stručnosti, a i gotovo uvek postoji subjektivni element. Kompjuterska analiza, ako se izvodi sa odgovarajućom pažnjom i logikom, može potencijalno dodati objektivnu snagu tumačenju stručnjaka. Na taj način postaje moguće poboljšati dijagnostičku tačnost i pouzdanost čak i stručnjaka sa dugogodišnjim iskustvom [26].

Kako su digitalne slike u širokoj upotrebi i koriste se u najrazličitijim aplikacijama, zahtevi za njihovu obradu mogu da idu od jednostavnog posvetljavanja slike, pojačavanja kontrasta pa sve to zahtevnih zadataka poput prepoznavanja osoba sa slike, detekcije raznih vrsta tumora i slično. U najgrubljoj podeli se mogu razlikovati tri nivoa obrade digitalnih slika.

Najniži nivo obrade uključuje sve filtere koji menjaju sliku bez ikakvog znanja o tome šta se na slici nalazi. Filter se primenjuje na matricu brojeva i rezultat je matrica brojeva koja predstavlja rezultat primenjene matematičke formule. U ovaj nivo obrade spadaju algoritmi za posvetljavanje i potamnijavanje slike, menjanje kontrasta, pravljenje negativa i slično. Svi ovi filteri menjaju vrednosti piksela po određenoj matematičkoj formuli i kao rezultat se dobija izmenjena slika bez daljih

informacija o njoj.

Drugi nivo obrade digitalnih slika je obrada na srednjem nivou u smislu detektovanja pojedinih elemenata slike. U ovaj nivo obrade spadaju algoritmi za detekciju ivica, razne vrste segmentacije, detekcije pojedinih objekata poput lica, drveća, registarskih tablica, saobraćajnih znakova i slično. Pri ovim obradama se prodrazumeva samo detektovanje odnosno izdvajanje željenih objekata. Algoritmi koji se koriste i dalje na ulazu imaju matricu brojeva dok na izlazu imaju ili obeležene piksele, odnosno delove slike, koji predstavljaju tražene objekte ili izračunate karakteristike relevantne za posmatrani problem (na primer prosečna osvetljenost ili opis teksture). Primer metode srednjeg nivoa obrade digitalnih slika je metoda za detekciju lica gde se traže regioni sa pikselima određenih nijansi raspoređenih u krug ili slično. Ukoliko je potrebno izdvojiti ivice, traže se delovi slike gde postoji velika promena u intenzitetu susednih piksela.

Najviši nivo obrade digitalnih slika se nadovezuje na drugi nivo obrade i uključuje neki vid veštačke inteligencije. Objektima koji su samo pronađeni i obeleženi u prethodnoj fazi sada se daje neki smisao. Ukoliko su se na primer pronalazili saobraćajni znakovi sada je potrebno odrediti i značenje tih znakova, u slučaju detekcije lica, sada bi bilo potrebno odrediti ko su osobe na slici, prepoznati broj na detektovanim registarskim tablicama i slično.

Algoritmi obrade digitalnih slika na sva tri nivoa predstavljaju aktivne istraživačke teme. Poboljšanje slika (engl. image enhancement) je prvi korak u većini aplikacija koje koriste digitalne slike. Potrebno je naglasiti da ne postoji jedinstvena definicija šta je poboljšanje slike, već se kvalitet definiše u zavisnosti od potrebe aplikacije. Na primer u slučaju detekcije nekih konkretnih anomalija na medicinskim slikama, može se smatrati da je slika poboljšana iako je veći deo detalja izgubljen, ali su detalji u regionima od interesa naglašeni.

Još jedan od zadataka algoritama obrade digitalnih slika je restauracija slika koja podrazumeva da je slika na neki način degradirana i cilj je odrediti na koji način i kako je degradirana kako bi se slika vratila u originalno stanje. Za razliku od poboljšanja slike gde je zadatak naglasiti karakteristike kako bi slika bila jasnija i bolja za dalju upotrebu, zadatak restauracija slika je da vrati digitalnu sliku u njeno originalno stanje koje nije nužno ni bolje ili ni gore.

Segmentacija slika je čest zadatak brojnih aplikacija te je samim time i aktivna tema istraživačkog rada naučnika iz različitih oblasti. Odnosi se na srednji nivo procesiranja gde je cilj izdvojiti neke karakteristike slike koje su bitne za razmatrani problem. Jedan od najjednostavnijih načina za segmentaciju slika je pretvaranje slike u binarnu tako da regioni odnosno objekti od interesa budu na primer bele boje, dok je pozadina crna ili obrnuto. Segmentacija slika je jedan od osnovnih zadataka prilikom obrade medicinskih slika. Obično su algoritmi za izdvajanje regiona od interesa na njima mnogo komplikovaniji od jednostavne binarizacije slike pa se koriste sofisticiraniji pristupi od kojih će neki biti obrađeni u ovom radu. U većini slučajeva nije dovoljno izdvojiti samo jednu vrstu objekata već je potrebno detektovati i razlikovati različite elemente slike te se koristi više pragova. U slučaju medicinskih slika često je potrebno razlikovati zdravo tkivo, krvarenja, različite vrste abnormalnosti, vene i slično.

Oblast obrade digitalnih slika koje je od velike važnosti za sve primene je kompresija slika. Zahvaljujući napretku tehnologije, danas je moguće prikupiti veliki broj slika u kratkom roku. Kada se govori o medicinskim slikama, više slika znači mogućnost preciznije analize a samim tim i tačnije dijagnoze, ali problem je čuvanje velike količine podataka. Za razliku od kompresije običnih slika gde gubici mogu biti neprimetni pa samim tim i nebitni, u slučaju gubitaka nekih detalja sa medicinskih slika može se desiti da se izgube medicinski bitni podaci pa je iz tog razloga potrebno prilagoditi algoritme kompresije za upotrebu na medicinskim slikama.

4.1 Spacijalni i frekventni domen

Digitalna slika je definisana matricom celih brojeva i može se opisati dvodimenzionalnom funkcijom $f(x, y)$ gde x i y predstavljaju koordinate, odnosno poziciju u matrici. Vrednost funkcije $f(x, y)$ predstavlja vrednost polja u koloni x i redu y u matrici inteziteta. U principu, obrada digitalnih slika je moguća u spacijalnom ili frekventnom domenu. Procesiranje digitalnih slika u spacijalnom domenu podrazumeva primenu formula direktno na matricu vrednosti piksela.

Ova reprezentacija digitalne slike nije nužno najpogodnija za obradu. Često se signali obrađuju u frekventnom domenu, pa ni slike, koje predstavljaju dvodimenzionalni signal, nisu izuzetak. Reprezentacija digitalnih slika u frekventnom domenu ima

dosta prednosti kao što su smanjenje prostora za čuvanje, jednostavnije uočavanje nekih osobina kao što su ivice ili šum.

Prelazak u frekventni domen se najčešće postiže primenom diskretne kosinusne transformacije (engl. discrete cosine transform, DCT). Nakon primene ove transformacije na matricu inteziteta dobija se matrica koeficijenata. Metode obrade digitalnih slika u frekventnom domenu, menjaju dobijene koeficijente koji ne sadrže spacijalnu informaciju. Upotrebom inverzne kosinusne transformacije dobija se ponovo matrica sa vrednostima piksela. DCT za dvodimenzionalne signale je definisana sledećom formulom:

$$D(u, v) = \left(\frac{2}{N}\right)^{\frac{1}{2}} \left(\frac{2}{M}\right)^{\frac{1}{2}} \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} C(i)C(j)I(i, j) \cos\left[\frac{\pi * u}{2 * N} * (2i + 1)\right] \cos\left[\frac{\pi * v}{2 * M} * (2j + 1)\right], \quad (11)$$

gde N i M predstavljaju veličinu slike, $I(i, j)$ je intezitet piksela na poziciji (i, j) . Funkcija $C(i)$ je definisana na sledeći način:

$$C(i) = \begin{cases} \frac{1}{\sqrt{2}} & \text{if } i = 0 \\ 1 & \text{otherwise} \end{cases} \quad (12)$$

Primenom formule 11 dobija se matrica $N \times M$ popunjena DCT koeficijentima. Prvi koeficijent, koji se još naziva DC komponenta, nosi najviše informacija o signalu, u ovom slučaju o slici. DC komponenta predstavlja prosečnu osvetljenost slike. Koeficijenti koji su bliži DC komponenti predstavljaju niske frekvencije što u praksi znači delove slike gde se intezitet sporo menja kao što bi na primer bili slika livade, mora i slični jednobojni objekti koji malo variraju u intezitetu. Nasuprot ovim koeficijentima, odnosno koeficijenti koji su bliži donjem desnom uglu matrice, predstavljaju visoke frekvencije što su delovi slike gde postoje velike promene u intezitetu. Ovim koeficijentima su predstavljene ivice, šum i slično.

Prevođenje u frekventni domen je reverzibilna operacija odnosno moguće je ponovo vratiti sliku u spacijalni domen bez gubitaka. Tačnije, postojaće minimalni gubici nastali usled zaokruživanja brojeva. Da bi se od DCT koeficijenata dobila ponovo slika

u specijalnom domenu potrebno je primeniti inverznu dvodimenzionalnu diskretnu kosinusnu transformaciju:

$$d(x, y) = \left(\frac{2}{N}\right)^{\frac{1}{2}} \left(\frac{2}{M}\right)^{\frac{1}{2}} \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} C(i)C(j)I(i, j) \quad (13)$$

$$\cos\left[\frac{\pi * u}{2 * N} * (2x + 1)\right] \cos\left[\frac{\pi * v}{2 * M} * (2y + 1)\right],$$

gde je korišćena ista notacija kao i u formuli 11.

koje se dovija komplementacijom vrednosti inteziteta

4.2 Manipulacija osvetljenjem slike

Medicinske slike su često niskog kontrasta što dovodi do lošeg kvaliteta slike. Takođe, prisutnost različitih tipova šumova je gotovo standardna pojava. Poboljšanje kontrasta boja, izoštravanje i manipulacija osvetljenjem su neke od korisnih tehnika koje se koriste da bi se generisale jasnije slike. Metode obrade medicinskih slika koriste ove tehnike za smanjenje šuma i izoštravanja detalja. Poboljšavanje slike je gotovo neophodno za pregled medicinskih slika kao što su MRI, ultrazvuk i slično [65].


Metode za obradu digitalnih slika su algoritmi i matematičke formule koje se primenjuju na matricu brojeva bilo da oni označavaju vrednost piksela ili DCT koeficijente dobijene transformacijom u frekventni domen. U slučaju slike u boji koja je predstavljena sa tri matrice, po jedna za svaku komponentu, filteri se mogu primenjivati na svakoj od njih ili se mogu različiti filteri koristiti za svaku komponentu.

Digitalni filteri za obradu slika se mogu definisati kao funkcija preslikavanja:

$$g(x, y) = T[f(x, y)] \quad (14)$$

gde $f(x, y)$ predstavlja sliku na koju se primenjuje operator T i kao rezultat operacije se dobija $g(x, y)$.

Jedna vrlo jednostavna transformacija koja može da se primeni u specijalnom domenu je dobijanje negativna. Negativ se dobija komplementacijom vrednosti inteziteta piksela. Ukoliko se radi o 8-bitnoj crno-beloj slici odnosno slici sa nijansama



Slika 19: *Negativ slike*

sive inteziteta od 0 do 255, tada se suprotna slika dobija:

$$g(x, y) = 255 - f(x, y) \quad (15)$$

Rezultat ovakvog operatora je prikazan na mamografskom snimku na slici 19. Ova veoma jednostavna transformacija je našla primenu posebno u medicini gde se često generišu slike na kojima dominiraju tamne nijanse. Kako bi lekarima bilo lakše da analiziraju dobijene slike, često se koristila ova transformacija. Iako je vizuelni sadržaj potuno identičan na obe slike, može se primetiti koliko se lakše vide promene tkiva na negativu [33]. Kako ova transformacija nema nikakvu praktičnu vrednost prilikom automatske obrade slika, već samo pri vizuelnoj analizi stručnjaka, ona se retko koristi u algoritmima automatske obrade medicinskih (a i drugih) digitalnih slika.

Drugi način naglašavanja regiona od interesa ili jednostavno olakšavanje vizuelne analize digitalnih slika je podešavanje kontrasta. Najjednostavnij filter u spacijalnom domenu za podešavanje kontrasta je korišćenje deo-po-deo linearne funkcije (engl. *piecewise linear function*). Filter koji koristi ovu vrste transformacije se naziva rastezanje kontrasta (engl. *contrast stretching*). To je proces gde se proširuju (rastežu) interval inteziteta slike tako da obuhvata ceo interval (npr. za 8-bitne slike od 0 do 255) [33].

Još jedan način za podešavanje kontrasta je korišćenje logaritamske i stepene transformacije koja je u procesiranju digitalnih slika poznata kao gama transformacija:




Slika 20: *Primena γ transformacije: original slika, $\gamma=0.3$ i $\gamma=1.5$*

$$g(x, y) = c \log(1 + f(x, y)) \quad (16)$$

$$g(x, y) = c f(x, y)^\gamma \quad (17)$$

U ovim formulama c i γ su pozitivne konstante. Primenom logaritamske transformacije, tamni delovi se proširuju dok se svetli delovi sabijaju, odnosno slika se potamnjuje na ovaj način. Što se tiče stepene, odnosno γ transformacije, rezultat zavisi od vrednosti parametra γ . Ukoliko je $\gamma < 1$ tada se transformacija ponaša slično logaritamskoj transformaciji sa razlikom da se može definisati više krivih. Ukoliko je parametar $\gamma > 1$ dobija se rezultat suprotan prethodno opisanom, odnosno proširuju se svetli delovi dok se tamni sabijaju čime se slika potamnjuje. Na slici 20 je prikazana primena ove transformacije.

Kontrast se može podešavati i pomoću histograma inteziteta piksela. Ovaj histogram je diskretna funkcija $h(l) = n_l$ gde je l intezitet i $0 \leq l \leq 2^L - 1$ za L -bitnu sliku (intezitet svakog piksela je predstavljen sa L bitova), a n_l predstavlja broj piksela koji imaju vrednost inteziteta l . Uobičajena je praksa da se histogram normalizuje pa se sve dobijene vrednosti dele sa ukupnim brojem piksela na slici: $p(l) = n_l / MN$ gde su M i N dimenzije slike. Vrednosti $p(l)$ predstavljaju verovatnoću pojavljivanja svakog od inteziteta. Da bi se podešavao kontrast, primenjuju se teoreme iz verovatnoće. Najpoznatije operacije su poklapanje histograma (engl. histogram matching) i ekvalizacija histograma (engl. histogram equalization). Rezultat primene ekvalizacije histograma je pokazana na primeru rendgenskog snimka na slici 21.



Slika 21: *Rezultat ekvalizacije histograma*

Opisane metode spadaju u grupu algoritama za nisku obradu digitalnih slika. Često se koriste za poboljšanje slike za dalju obradu metodama srednjeg nivoa. Jedan od glavnih zadataka algoritama srednjeg nivoa obrade digitalnih slika je segmentacija.

4.3 Segmentacija

Velikom broju aplikacija koje koriste digitalne slike je jedan od zadataka, ako ne i glavni, segmentacija. Segmentacija particioniše sliku u različite regije koje sadrže piksele sa sličnim atributima [25]. Svrsihodna segmentacija je metod obrade slike srednjeg nivoa, najčešće praćen metodama visokog nivoa procesiranja koji daju smisao pronađenim segmentima. Uspeh analize slika zavisi od pouzdanosti segmentacije što je generalno veoma izazovan problem pogotovo kada su u pitanju medicinske slike.

Jedna od opštih podela metoda segmentacija bi mogla da bude sledeće [25]:

- Metode zasnovane na granicama (engl. boundary-based methods): u ovu grupu spadaju razni algoritmi detekcija ivica, praćenja kontura i slično.
- Metode koje koriste trešhold vrednosti (engl. thresholding): kod ovih metoda glavni cilj je pronaći pragove inteziteta odnosno trešhold vrednosti koje određuju intervale segmenata. Potrebno je pronaći takve vrednosti da segmentacija bude smisljena.
- Metode zasnovane na regionima (engl. region-based methods): u ovu grupu spadaju metode koje spajaju pojedine regione sa sličnim karakteristikama u jednu klasu odnosno segment. Najčešće se kombinuju sa algoritmima mašinskog

učenja koji određuju pripadnost segmentima na osnovu izabranih kriterijuma sličnosti.


Detekcija ivica se odnosi na proces identifikacije i lociranja oštih diskontinuiteta na slici. Diskontinuiteti su nagle promene u intenzitetu susednih piksela koje karakterišu granice objekata. Klasične metode detekcije ivica uključuju konvoluciju slike sa operatorom (primenu 2D filtera) koji je konstruisan tako da bude osetljiv na velike gradijente dok vraćaju vrednost nula u uniformnim regionima. Detekcija ivica je čest zadatak u mnogim aplikacijama pa je samim tim i aktivna istraživačka tema. Rezultat istraživanja je postojanje izuzetno velikog broja operatora za otkrivanje ivica.

Jedan od vrlo jednostavnih ideja za detekciju ivica je oduzimanje omekšane slike od njenog originala. Ovaj filter se naziva *unsharp mask*. Algoritam je vrlo intuitivan: omekšati odnosno zamutiti originalnu sliku, oduzeti rezultujuću sliku od originala i dobijene su ivice. Dodavanjem dobijenih ivica originalnoj slici dobija se slika sa jasnije definisanim ivicama. Ivice se mogu dodatno naglasiti ukoliko se dobijene ivice pre dodavanja originalnoj slici pomnože sa nekim pozitivnim koeficijentom. U tom slučaju se radi o *high boost* filteru.

Omekšavanje slike je moguće uraditi na više načina, na primer uprosečavanjem ili median filterom. Ovi filteri nisu definisani nad jednim poljem matrice slike već uzimaju u obzir i njegovo susedstvo. U procesiranju digitalnih slika najčešće se koriste 4-susedstvo odnosno posmatraju se pikseli gore, dole, levo i desno od piksela nad kojim se primenjuje operator ili 8-susedstvo gde se posmataju svi okolni pikseli na udaljenosti 1. Za različite aplikacije se susedstvo ponekad proširuje tako da se gledaju i pikseli koji su na većoj udaljenosti, zatim susedstvo pravougaonog ili uslovno rečeno kružnog oblika. Slika 22 ilustruje primenu filtera koji uzima 8-susedstvo.

Uprosečavanje podrazumeva postavljanje centralnog piksela na prosečnu vrednost njegovog susedstva. Varijanta ovog filtera je težinsko uprosečavanje gde se bliži susedi množe sa većim a dalji sa manjim koeficijentom. Median filter radi po istom principu samo što se centralni piksel postavlja na medianu umesto na prosečnu vrednost. Ovi filteri i njihove modifikacije se u obradi medicinskih slika često koriste za otklanjanje različitih vrsta šuma.

Kako ivice predstavljaju veliku razliku u intezitetima susednih piksela, očigledno je da se može koristiti neka metoda bazirana na izvodu ili gradijentu. Diferencijacija



Slika 22: *Primena digitalnog filtera koji koristi 8-susedstvo*

je u suštini oduzimanje dve vrednosti i deljenje te vrednosti korakom koji ih razdvaja. Ako je korak jednak jedan (susedni pikseli iz 4-susedstva), onda je ovo deljenje suvišno. Magnituda gradijenta se koristi za izračunavanje jačine ivice. Gradijentna magnituda ima svojstva lokalnih usmerenih maksimuma i pomaže u računskoj orijentaciji lokalne ivice koja je u smeru gradijenta. U metodi zasnovanoj na Laplasu, slika se koristi za izračunavanje izraza derivata drugog reda.

Ivice na digitalnoj slici se mogu uspešno detektovati i u frekventnom domenu. Naime, visoke frekvencije predstavljaju nagle promene u vrednosti inteziteta, te poništavanjem koeficijenata niskih frekvencija (što predstavlja uniformne delove slike) i zadržavanjem samo visokih frekvencija se mogu dobiti ivice. Ovaj filter se naziva *highpass* filter odnosno filter koji propušta samo visoke frekvencije. U zavisnosti od aplikacije i same digitalne slike, broj koeficijenata koji se zadržava može da varira. Nasuprot ovom filteru postoji *lowpass* filter koji postavlja koeficijente visokih frekvencija na nulu i time briše podatke o ivicama (i šumu), što rezultuje omekšanom slikom. Formalno, ako su koeficijenti poredani u matrici $N \times N$ onda *highpass* filter zadržava koeficijente čiji indeksi zadovoljavaju uslov $i + j > k$ gde su i i j indeksi elementa u matrici a k pozitivna konstanta koja određuje koliko se koeficijenata zadržava. Suprotno, *lowpass* filter zadržava koeficijente sa indeksima za koje važi $i + j < k$.

Nakon primene nekog algoritma za detekciju ivica, obično je potrebno te ivice malo korigovati. Često se dešava da postoje pikseli koji su van ivica prepoznati kao ivica i obrnuto. Rezultat je neprecizna kontura ivica sa prekidima. Ovaj problem se može rešiti korišćenjem morfoloških operacija otvaranja i zatvaranja odnosno erozijom i dilatacijom. Ove operacije se takođe koriste za uklanjanje *so i biber* šuma

(engl. salt and peper noise) što su zapravo crni i beli pikseli koji se nasumično pojavljuju na slici.

Dilatacija je operacija koja u binarnim slikama povećava veličinu objekata sačinjenih od belih piksela. Algoritam je sledeći: prelazi se maskom određene veličine preko svakog piksela ulazne slike tako da se središte maske podudara sa pozicija ulaznog piksela. Ako se najmanje jedan piksel maske podudara sa pikselom objekta na slici ispod, uključujući i piksel koji se testira, onda se svi pikseli pokriveni maskom postavljaju na vrednosti makse. Kod dilatacije je maska sačinjena od svih belih piksela. Prema tome, neki od crnih piksela ulazne slike postaju beli na izlaznoj slici (oni koji su bili beli ostaju beli). U slučaju 8-susedstva, ako crni piksel ima najmanje jedan beli piksel u susedstvu, tada postaje beli. Pikseli koji se menjaju su pikseli koji leže na ivicama belih regiona na ulaznoj slici, tako da je posledica da beli regioni rastu u veličini, što može da rezultuje povezivanjem ili spajanjem tih regiona [25]. Dilatacija je često prateća operacija metoda za detekciju ivica ili neku drugu vrstu binarne segmentacije kako bi se popravile potencijalne sitne nepravilnosti i povezale konture.

Dilatacija takođe može da se koristi za pronalaženje obrisa objekata na binarnoj slici. Ako se dilatacija primeni jednom na binarizovanu sliku, pa se od rezultujuće oduzme originalna slika, rezultat je širi obris belih regiona originalne slike [25].

Uslovno rečeno, erozija predstavlja operaciju suprotnu dilataciji. Razlika je što erozija proširuje crne regione na isti način kao dilatacija samo koristeći masku popunjenu vrednostima crne boje.

Dodatni operatori matematičke morfologije mogu se definisati u smislu kombinacija erozije i dilatacije, zajedno sa skupovnim operacijama kao što su razlika i unija. Neki od važnijih operatora ove vrste su otvaranje, zatvaranje i skeletonizacija.

Otvoravanje je definisano kao erozija praćena dilatacijom gde obe operacije koriste iste veličine maske. Erozija uklanja neke svetle piksele iz ivica regiona belih piksela, dok dilatacija dodaje svetle piksele. Kao i kod same erozije, uski delovi su slomljeni i tanke izbočine eliminisane.

Suprotno otvaranju postoji zatvaranje definisano kao dilatacija praćena erozijom korišćenjem istog strukturalnog elementa za obe operacije.

Opisani algoritmi detekcije ivica predstavljaju najjednostavnije metode koje

često nisu dovoljno dobre za praktične aplikacije. Kao što je već rečeno, detekcija ivica predstavlja osnovu za mnogo probleme obrade digitalnih slika te je predložen veliki broj metoda. Neke od najpoznatijih su Kanijev operator za detekciju ivica (engl. Canny edge detection), Sobelov operator, Robertov operator i drugi. U prvu grupu metoda za segmentaciju spadaju i mnogi algoritmi za praćenje konture (engl. boundary tracking)

Druga grupa algoritama za segmentaciju slika su metode koje koriste trešhold vrednosti. U ovim metodama specijalni odnos piksela je zanemaren i svakom segmentu pripadaju pikseli koji imaju intezitet u nekom određenom intervalu.

Cilj je da se pronađu optimalne vrednosti trešholda koje na odgovarajući način raščlanjuju sliku. Najjednostavnija je podela na dva nivoa gde je potrebna samo jedna trešhold vrednost. Svi pikseli na slici sa intezitetom većim od te vrednosti pripadaju jednoj grupi, na primer pozadini, a pikseli sa nižim intezitetima su deo druge grupe, objekata od interesa. Za traženje optimalnih trešhold vrednosti predloženo je mnogo različitih metoda. Jedna od njih je Kapurova metoda. Kapur et al. u [44] predlaže maksimizaciju entropije histograma intenziteta za pronalaženje optimalne trešhold vrednosti. Predložen je neparametarski pristup za segmentaciju na dva nivoa, odnosno sa jednom trešhold vrednošću, ali se može generalizovati i primeniti i za određivanje trešhold vrednosti za segmentaciju u više nivoa. Još jedna dobro poznata metoda koja se koristi za segmentaciju slike je Otsu-ova metoda [63] gde su vrednosti intenziteta podeljene u klase, tako da je varijansa unutar jedne klase minimalna.

Određivanje optimalnih graničnih vrednosti je veoma važan zadatak za segmentaciju slike i može se uraditi posmatranjem histograma intenziteta. Glavna funkcija histograma intenziteta je da pruži statističke informacije o slici. Histogram intenziteta ne sadrži informacije o položaju piksela. Metode za određivanje optimalnih trešhold vrednosti pokušavaju da histogram podele na klase koje bi zadovoljile neke kriterijume. Kapurova i Otsuova metoda određivanja trešhold vrednosti koriste teoriju verovatnoće. Kapurova metoda se još naziva metoda kriterijuma entropije. Kapurova metoda se zasniva na Šanonovoj meri entropije informacija. Dizajniran je da maksimizuje količinu informacija između dva dela histograma intenziteta koji su odvojeni trešhold vrednošću. Cilj Kapurove metode je da maksimizuje entropiju

dela histograma tako da svaki deo ima centralizovanu distribuciju. Početni rad u kojem je predložen Kapurov metod definiše metodu za segmentaciju na dva nivoa. Predloženi metod se može opisati na sledeći način. Pretpostavimo da u datoj slici ima L sivih nivoa (inteziteta), tako da je opseg sivih nivoa između 0 i $L - 1$. Ako se slika sastoji od N piksela i broj piksela sa intenzitetom nivoa i se označava sa $h(i)$, onda $P_i = \frac{h(i)}{N}$ predstavlja verovatnoću intenziteta i . Cilj Kapurove metode je maksimizacija sledeće funkcije cilja:

$$f(t) = H_0 + H_1 \quad (18)$$

gde je:

$$\begin{aligned} H_0 &= - \sum_{i=0}^{t-1} \frac{P_i}{\omega_0} \ln \frac{P_i}{\omega_0}, & \omega_0 &= \sum_{i=0}^{t-1} P_i \\ H_1 &= - \sum_{i=t}^{L-1} \frac{P_i}{\omega_1} \ln \frac{P_i}{\omega_1}, & \omega_1 &= \sum_{i=t}^{L-1} P_i \end{aligned} \quad (19)$$

Optimalna threshold vrednost t je ona za koju se postiže maksimalna vrednost funkcije definisane jednačinom (18).

Opisani metod se može proširiti i primeniti za pronalaženje više threshold vrednosti. Ovaj problem se može smatrati m -dimenzionalnim optimizacionim problemom, gde je m broj željenih threshold vrednosti, pa je potrebno odrediti m optimalnih threshold vrednosti $[t_1, t_2, \dots, t_m]$. U ovom slučaju, cilj je maksimizovati sledeću funkciju cilja:

$$f(t) = H_0 + H_1 + \dots + H_m, \quad (20)$$

gde je:

$$\begin{aligned} H_0 &= - \sum_{i=0}^{t_1-1} \frac{P_i}{\omega_0} \ln \frac{P_i}{\omega_0}, & \omega_0 &= \sum_{i=0}^{t_1-1} P_i \\ H_1 &= - \sum_{i=t_1}^{t_2-1} \frac{P_i}{\omega_1} \ln \frac{P_i}{\omega_1}, & \omega_1 &= \sum_{i=t_1}^{t_2-1} P_i \\ & & & \vdots \\ H_m &= - \sum_{i=t_m}^{L-1} \frac{P_i}{\omega_m} \ln \frac{P_i}{\omega_m}, & \omega_m &= \sum_{i=t_m}^{L-1} P_i. \end{aligned} \quad (21)$$

Još jedna dobro poznata metoda koja se koristi za segmentaciju slike je Otsuova metoda [63] gde su sive vrednosti podeljene u klase, tako da je varijansa unutar klase minimalna, tj. prvi korak u Otsuovoj metodi je izračunavanje kumulativnih verovatnoća za svaku klasu A_i gde je $i = 0, 1, \dots, m$. Pretpostavljajući ranije opisane verovatnoće P_i , kumulativne verovatnoće se računaju sledećim formulama:

$$w_0 = \sum_{i=0}^{t_1-1} P_i, \quad w_1 = \sum_{i=t_1}^{t_2-1} P_i, \quad \dots, \quad w_m = \sum_{i=t_m}^{L-1} P_i \quad (22)$$

gde t_l predstavljaju trešhold vrednosti koje se koriste za odvajanje klasa. Optimalne trešhold vrednosti u Otsuovoj metodi su dobijene maksimizacijom sledeće funkcije cilja:

$$f(t_1, t_1, \dots, t_m) = \sum_{i=0}^m \sigma_i \quad (23)$$

gde su funkcije σ_i definisane kao:

$$\begin{aligned} \sigma_0 &= w_0 \left(\sum_{i=0}^{t_1-1} \frac{ip_i}{w_0} - \sum_{i=0}^{L-1} ip_i \right)^2 \\ \sigma_1 &= w_1 \left(\sum_{i=t_1}^{t_2-1} \frac{ip_i}{w_1} - \sum_{i=0}^{L-1} ip_i \right)^2 \\ &\vdots \\ \sigma_m &= w_k \left(\sum_{i=t_m}^{L-1} \frac{ip_i}{w_k} - \sum_{i=0}^{L-1} ip_i \right)^2 \end{aligned} \quad (24)$$

U Kapurovoj i Otsuovoj metodi cilj je da se maksimizuju funkcije cilja gde su trešhold vrednosti parametri. Povećanjem broja željenih trešhold vrednosti problem postaje računski kompleksan. Deterministički metod pronalaženja globalnih optima ovih funkcija postaje neupotrebljiv jer se rešenje ne može dobiti u razumnom vremenskom periodu čak i pri relativno malim dimenzijama problema, odnosno broju trešhold vrednosti koje bi trebalo pronaći. Za rešavanje ovih optimizacionih problema, potrebno je koristiti neki heuristički metod kao što su algoritmi inspirisani prirodom i posebno algoritmi inteligencije rojeva.

Treća grupa algoritama za segmentaciju slika je zasnovana na regionima. Kod ovih metoda se za razliku od trešholding metoda posmatraju regioni slika i njihove karakteristike a ne pojedinačni pikseli. Regioni se mogu smatrati minijaturnom

digitalnom slikom, tako sve karakteristike koje se mogu izdvojiti na nivou cele slike se mogu koristiti i za opisivanje regiona. Na primer, broj piksela ivica može da opisuje region ili prosečna osvetljenost, intenzitet određenih komponenti boja, tekstura, itd. Da bi se ispravno povezali regioni sa sličnim karakteristikama, odnosno regioni slični po nekoj metrici, često se koriste različiti algoritmi mašinskog učenja i to klasifikacija i klasterovanje.

O intezitetima i modelima boja je bilo reči ranije. Kod metoda zasnovanim na regionima, novi momenat je korišćenje deskriptora tekstura. Jedan od dosta korišćenih deskriptora u procesiranju medicinskih slika je lokalni binarni uzorak (engl. local binary pattern, LBP). Ovaj deskriptor teksture je vrlo jednostavan, ali moćan. Ideja je da se lokalna struktura predstavi binarnim kodom. Centralni piksel se koristi kao prag vrednosti za susedne piksele. Ako je vrednost intenziteta piksela veća ili jednaka centralnom pikselu, ona se postavlja na jedan, u suprotnom se postavlja na nulu. Formalna definicija je data sledećim izrazom:


$$s(i) = \begin{cases} 1, & \text{if } p(i) \geq p \\ 0, & \text{inače} \end{cases} \quad (25)$$

gde p predstavlja intezitet centralnog piksela a $p(i)$ je intezitet piksela i iz definisanog susedstva.

Nove vrednosti susednih piksela se mogu čitati nekim redosledom, obično u smeru kazaljke na satu kako bi se dobio binarni uzorak. Osnovna verzija lokalnog binarnog uzorka koristi 8-susedstvo. U tom slučaju, binarni uzorak će biti 8-cifarni binarni broj tako da će opisati do $2^8 = 256$ različitih lokalnih uzoraka teksture. Ako je izabrano susedstvo od 5×5 , broj uzoraka je 2^{16} . U literaturi se mogu naći različito odabrano susedstva u zavisnosti od primene.

Ovako pročitani binarni uzorci se mogu transformisati u decimalne brojeve. Kao što je ranije pomenuto, za 8-susedstvo može se razlikovati 256 različitih uzoraka tako da će decimalni broj biti u rasponu $[0, 255]$. Primer dobijanja uzorka je prikazan na slici 23.

Na osnovu uzoraka dobijenih na slici može se napraviti histogram. Ovaj histogram predstavlja učestalost pojavljivanja svakog od uzoraka. U ovom slučaju histogram bi bio predstavljen kao 256-dimenzionalni vektor.



Slika 23: *Primer LBP-a za 8-susedstvo*

U praksi se često umesto kompletnog histograma uzimaju samo neke statističke karakteristike i mere. Brojne metrike se koriste za pružanje korisnih informacija na osnovu histograma. Neke od najčešće korišćenih su prosečna vrednost (μ), standardna devijacija (σ), asimetrija (skewness), kurtosis, energija i entropija, itd. Ako je normalizovani histogram označen sa p i N predstavlja broj vrednosti histograma, onda se ove metrike mogu izračunati pomoću sledećih jednačina:

$$\mu = \sum_{i=0}^N i * p(i) \quad (26)$$

$$\sigma = \sqrt{\sum_{i=0}^N (i - \mu)^2 * p(i)} \quad (27)$$

$$skewness = \frac{1}{\sigma^3} \sum_{i=0}^N (i - \mu)^3 * p(i) \quad (28)$$

$$kurtosis = \frac{1}{\sigma^4} \sum_{i=0}^N (i - \mu)^4 * p(i) \quad (29)$$

$$energy = \sum_{i=0}^N p(i)^2 \quad (30)$$

$$entropy = - \sum_{i=0}^N p(i) * \log_2 p(i) \quad (31)$$

Jedna od LBP karakteristika je da sve dok je relativni odnos između intenziteta piksela sačuvan nakon primene nekih transformacija, LBP ostaje isti. LBP je široko proučavan u prošlosti, tako da se brojne modifikacije LBP mogu naći u

literaturi. Jedna od veoma poželjnih karakteristika deskriptora teksture je rotacijska invarijantnost i predložene su različite promene definicije LBP-a kako bi se to postiglo.

Uniformni LBP obrazac je rotaciona invarijantna verzija LBP deskriptora koji smanjuje broj uzoraka koji se razlikuju prilikom korišćenja istog susedstva. Smatra se jednom od najkorisnijih modifikacija osnovnog LBP operatora. Ona grupiše sve obrasce koji imaju više od dva prelaza sa 0 na 1 ili sa 1 na 0 u jedan obrazac. U ovom slučaju umesto 256 uzoraka, ostaće samo 59. Postoji 58 obrazaca sa manje od dva prelaza i jedan je za sve ostale.

Jedan od poznatijih algoritama za segmentaciju baziran na regionima je metoda širenja regiona (engl. region growing). Ovaj algoritam počinje sa *seme* pikselima ili regionima (engl. seed pixel/region) i od njih se širi region dodajući susedne regione ukoliko su slični na osnovu nekog kriterijuma kao što su boja, tekstura, gradijent, geometrijska svojstva, itd. [25]. Algoritmi klasterovanja se ponekad koriste kako bi se odredila početna semena.


Automatizovana klasifikacija predstavlja osnovu za dijagnostiku uz pomoć računara u oblasti obrade medicinskih slika [25]. Segmentacija regiona se može posmatrati kao problem klasifikacije gde je potrebno izabrati karakteristike koje dobro opisuju regione, ističu sličnosti među regionima koji bi trebalo da su unutar jednog segmenta, a sa druge strane pomoću tih karakteristika se jasno razlikuju regioni iz različitih segmenata. Ovo u praksi nije lako postići te se često koristi veliki broj karakteristika u nadi da će klasifikator pronaći te sličnosti i razlike. U ovim metodama, kvalitet i osobine klasifikatora su od izuzetne važnosti.

Jedan od najboljih klasifikatora je mašina potpornih vektora (engl. support vector machine, SVM). SVM je binarni klasifikator, ali se široko koristi kao multiklasifikator koristeći algoritme *jedan protiv jednog* (engl. one against one) ili *jedan protiv svih* (engl. one against all). Metoda *jedan protiv svih* gradi SVM modele za svaku klasu nasuprot klasi koja sadrži sve instance iz ostalih klasa, dok *jedan protiv jednog* pravi modele suprotstavljajući svake dve klase i konačnu odluku o klasi instance donosi metodom glasanja.

Osnovna ideja za SVM je da pronađe hiperravan koja razdvaja instance različitih klasa što je moguće uz pretpostavku da je skup instanci linearno razdvojiv. Ova definicija SVM-a koristi takozvanu tvrdu marginu - instancama nije dozvoljeno

da budu sa pogrešne strane hiperravni. Kako je ovo u praksi gotovo nemoguće scenario, uvodi se parametar takozvane meke margine C koji kontroliše cenu pogrešno klasifikovanih instanci. Ukoliko se postavi na beskonačno veliku vrednost, ponovo se vraća na definiciju tvrde margine. Za previše male vrednosti ovog parametra, pogrešna klasifikacija ni na koji način ne utiče na model tako da je ovo gotovo ekvivalentno postavljanju hiperravni na slučajan način. Odavde je jasno da je parametar C potrebno pažljivo odabrati i to za svaki problem posebno.

Druga stvar koja je učinila SVM toliko efikasnim za klasifikaciju najraznovrsnijih skupova podataka je kernel funkcija. Nekada skup podataka nije linearno razdvojiv, ali može biti preslikan u prostor veće dimenzije gde bi to postao. Funkcija koja mapira instance u prostor veće dimenzije naziva se kernel funkcija ili jezgrena funkcija. Jednostavan primer koji ilustruje kako kernel funkcija može da pomogne je prikazan na slici 24 gde pre upotrebe kernel funkcije, bilo koja prava koja prolazi kroz centar kruga koji formiraju instance jednako loše razdvaja klase. Preslikavanjem instanci u 3-dimenzionalni prostor, ovaj skup postaje linearno razdvojiv, te se lako pronalazi ravan koja razdvaja instance različitih klasa.



Slika 24: Preslikavanje podataka pomoću kernel funkcije: $(x_i, x_j) \rightarrow (x_i, x_j, x_i^2 + x_j^2)$

Gusova (radial basis function, RBF) je jedna od najčešće korišćenih kernel funkcija:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2). \quad (32)$$

Parametar γ je slobodan parametar koji ima značajan uticaj na tačnost klasifikacije. Ovaj parametar određuje uticaj svake instance iz trening skupa. Da bi se maksimalno iskoristion potencijal SVM metode, potrebno je pronaći optimalan par vrednosti za

(C, γ) . Ovo je težak optimizacioni problem i potrebno je koristiti heurističke metode za njegovo rešavanje.

4.4 Frekventne komponente i kompresija

Prednosti korišćenja digitalnih slika su brojne, ali postoje i neki problemi. Jedan od većih problema je prostor potreban za čuvanje digitalnih slika. Jedna digitalna slika visokog kvaliteta obično se sastoji od miliona piksela i prema tome potrebno je više od deset megabajta memorije za njen zapis. Jedno od rešenja za ovaj problem je korišćenje tehnika kompresije koje zapisuju podatke slika u nekom formatu koji bi koristio manje memorije.

Uopšteno, mogu se razlikovati dva različita tipa tehnika kompresije: algoritmi bez gubitaka (engl. lossless) i sa gubitcima (engl. lossy). Kao što ime sugerise, metode kompresije bez gubitaka smanjuju veličinu slike tako što pronalaze neke konzistencije i redundancije u podacima piksela i koriste ih za kompaktniji način zapisa slike. Kompresija slike je reverzibilna, tako da se može dobiti originalna slika kao i pre kompresije. To je prednost algoritama kompresije bez gubitaka, ali problem je što je razmera kompresije prilično mala, do 2:1 ili 3:1 što nije zadovoljavajuće za veliku količinu slika visokog kvaliteta. Zbog ovog problema, predloženi su algoritmi za kompresiju sa gubitcima i naširoko se koriste zbog činjenice da se može postići dobar odnos kompresije i gubitka informacije, a kompresija može da smanji količinu memorije potrebnu za zapis slike 10 ili čak 100 puta.

JPEG algoritam je jedan od najčešće korišćenih metoda kompresije sa gubitcima zbog činjenice da se može značajno smanjiti prostor potreban za skladištenje slike uz očuvanje vizuelnog kvaliteta. JPEG je algoritam se sastoji od nekoliko koraka.

Prvi korak u JPEG algoritmu smanjuje veličinu slike upotrebom činjenice da ljudsko oko nije jednako osetljivo na boje i na promene intenziteta svetla. Da bi se koristila ova činjenica, digitalna slika se transformiše u HSV prostor boje (ili neki drugi model gde je komponenta osvetljenosti izdvojena, npr. YCbCr). Komponente boje se tada zapišu u kraćem formatu, odnosno koristi manje bitova za njihov zapis. Ovaj korak smanjuje veličinu slike.

Drugi korak je transformacija slike u frekventni domen koji se postiže primenom dvodimenzionalne diskretne kosinusne transformacije (DCT). DCT se izvodi nad

komponentom intenziteta svetlosti i to se primenjuje na nepreklapajuće blokove veličine 8×8 . Nakon ovog koraka, slika se transformiše u matricu dimenzije originalne slike podeljenje na blokove 8×8 , gde svaki blok sadrži 64 frekventnih koeficijenata.

Kada se slika transformiše u frekventni domen, izvodi se korak kvantizacije gde se postiže glavna kompresija. Nivo kompresije kao i kvalitet slike na koju je primenjen JPEG algoritam je najviše određen upravo ovim korakom. U ovom koraku se koriste kvantizacione tabele. Kompresija se postiže odbacivanjem nekih od manje važnih DCT koeficijenata i smanjivanjem preciznosti preostalih elemenata. Ovo se postiže deljenjem DCT koeficijenata odgovarajućim elementima iz kvantizacione tabele. U zavisnosti od elemenata kvantizacione tabele, mogu se postići različiti nivoi kompresije što rezultira različitim kvalitetima slike. Kvalitet slike neće biti promenjen i kompresija neće biti izvršena ako su svi elementi u kvantizacionoj tabeli jednaki jedinici.

Postoje empirijski dobijene, preporučene, kvantizacione tabele. Ove tabele su nazvane Q_k gde $k = 1, 2, \dots, 100$ predstavlja skalu za kvalitet dekompresovane slike. Tabela kvantizacije Q_{50} se koristi kao osnovna tabela jer ima dobar odnos nivoa kompresije i kvaliteta dekompresovane slike. Sve ostale kvantizacione tabele izračunate su na osnovu Q_{50} . Za veći kvalitet, ali manju kompresiju (Q_k gde $50 < k \leq 100$), kvantizacione tabele su izračunate množenjem elemenata matrice Q_{50} sa $(100 - k)/50$. Niži kvalitet i viši nivo kompresije (tabele Q_k gde je $1 \leq k < 50$) se postiže kvantizacionim tabelama dobijenim množenjem Q_{50} sa $50/k$. Elementi kvantizacione tabele su uglavnom svedeni na opseg $[1, 255]$.

Standardne kvantizacione tabele Q_k su dobijene na osnovu ljudske percepcije koja nije objektivna mera. Za brojne primene gde se kompresovane slike dalje analiziraju i obrađuju potrebne su objektivne mere kvaliteta koja je povezana sa specifičnim ciljem aplikacije [84], [1].

Za razliku od kompresije običnih slika gde gubitci mogu biti neprimetni pa samim tim i nebitni, u slučaju gubitaka detalja sa medicinskih slika može se desiti da se izgube medicinski bitni podaci pa je iz tog razloga potrebno prilagoditi algoritme kompresije za upotrebu u medicini.

5 Teški optimizacioni problemi

Optimizacija je najrasprostranjenija tehnika u ljudskom životu i aktivnostima. Postoji mnoštvo primera situacija u kojima je potrebna optimizacija: pronalaženje najkraćeg ili najbržeg puta do nekog odredišta, odabir najboljeg proizvoda pri kupovini, maksimizacija efikasnosti proizvodnih procesa, ostvarivanje maksimalnog profita pri investicijama, planiranje puštanja traka za određeni smer u saobraćaja kako bi se smanjila zagušenost, itd. Optimizacija predstavlja pronalaženje alternative sa najisplativijim performansama za date parametre pod određenim ograničenjima, odnosno maksimizacija željenih i minimizacija neželjenih faktora. Najčešći primeri su minimizacija troškova ili maksimizacija dobiti, efikasnosti, kvaliteta, itd. Neki primer optimizacije, poput onih prethodno navedenih, su očigledni, dok drugi ne moraju biti, kao na primer: neki od problema razmatranih u ovom radu, problemi automatizovane dijagnostike gde je potrebno klasifikovati određene medicinske podatke, a klasifikacija predstavlja problem optimizacije.

Pronalaženje najboljeg rešenja, odnosno optimizacija, najčešće podrazumeva konstruisanje matematičkog modela za opisivanje odgovarajućeg problema. Problemi iz života se ponekad vrlo jednostavno i prilično direktno predstavljaju kao problemi numeričke optimizacije, dok je u drugim slučajevima neophodno prilagođavanje problema kako bi se formulisao matematički model. Dobijeni modeli su obično kompleksni i zavise od velikog broja varijabli. Tokom proteklih vekova matematika se razvijala i uspeła da pronađe metode za rešavanje mnogih matematički teških problema.


Za mnoge probleme su postojala teorijska rešenja koja su postala praktično moguća tek pojavom računara. Ove metode su bile suviše kompleksne za izračunavanje, te je tek pojavom računara, koji su mogli da obave na milione aritmetičkih operacija u sekundi, postalo moguće izračunati ih. Ova rešenja nisu nužno zahtevala komplikovane operacije, ali je čoveku bilo potrebno neprihvatljivo mnogo vremena za račun. Neki od primera mogu biti množenje ili invertovanje matrica velikih dimenzija. Lako se može steći utisak da računar ima dovoljnu moć da reši svaki problem u relativno kratkom (razumnom) vremenskom periodu. Međutim postoje problemi koje nije moguće rešiti čak ni pomoću računara u razumnom vremenskom periodu. Jedan od primera ovakvih problema je problem putujućeg trgovca. Za ovaj problem je sasvim

jednostavno definisati i implementirati algoritam, algoritam koji proverava sve moguće putanje, ali ga nije moguće izvršiti u razumnom vremenskom periodu već za relativno mali broj gradova. Za ovakve probleme ne postoji efikasan način rešavanja pošto je skup mogućih rešenja toliko veliki da je potrebno na hiljade godina da računari pronađu najbolje rešenje determinističkom metodom koja bi proveravala sva moguća rešenja. Problem putujućeg trgovca pripada klasi eksponencijalnih kombinatornih problema i napredak u tehnologiji izrade procesora, ma koliko impresivan bio u odnosu na druge oblasti, neće pomoći izračunavanju rešenja ovakvih problema koji imaju eksponencijalan broj rešenja. Postoje mnogi slični kombinatorni problemi, kao i mnogi ekvivalentno teški kontinualni problemi optimizacije koji uključuju traženje globalnog optimuma visoko nepravilnih i nelinearnih funkcija sa velikim brojem lokalnih optimuma.

Veliki broj optimizacionih problema iz realnog života pripada ovoj klasi teških optimizacionih problema ili klasi NP-teških problema. Neki od primera su već pomenuti problem trgovačkog putnika, planiranje putanje robota (bespilotnih letelica, podvodnih vozila, i dr.), dizajniranje senzorskih mreža, određivanje optimalnih lokacija u raznim sistemima, pomenuto određivanje optimalnih trešhold vrednosti za segmentaciju slika i mnogi drugi.

Početna ideja za pronalaženje rešenja za teške optimizacione probleme je generisanje slučajnih rešenja. Ova metoda je poznata kao Monte Karlo metoda koja generiše veliki broj slučajnih rešenja iz domena i najbolje među njima se uzima kao aproksimacija optimalnog rešenja. Jasno je da je u kontinualnom sistemu verovatnoća nalaženja optimalnog rešenja jednaka nuli, dok je u diskretnim sistemima sa eksponencijalno mnogo rešenja bliska nuli, ali sa povećanjem broja generisanih rešenja povećava se i kvalitet najboljeg pronađenog rešenja. Ako bi se za ilustraciju uzeo primer n -dimenzionalne sfere, koja je jednostavna funkcija čiji je globalni minimum poznat, jasno je da Monte Karlo metoda koja nema nikakvo vođenje, već potencijalna rešenja generiše na potpuno slučajan način, za pronalaženje kvalitetnog sub-optimalnog rešenja mora generisati veliki broj tačaka.

Sledeća ideja je da bi se mogla generisati bolja rešenja ukoliko bi se slučajna pretraga na neki način navodila ka optimalnom rešenju. Vođenje bi bilo zasnovano na prethodnim iskustvima i može se očekivati da se ubrza proces i poboljša kvalitet



Slika 25: *Sfera*


optimizacionog algoritma. Ako bi se opet posmatrala n -dimenzionalna sfera kao primer, algoritam se može usmeravati ka nižim vrednostima. Za samo dva slučajno generisana rešenja može se odrediti smer "nizbrdo" i nova rešenja mogu se generisati samo na tu stranu. Na ovaj način značajno se smanjuje broj rešenja koje je potrebno generisati i može se u relativno malom broju iteracija pronaći globalni optimum sa željenom preciznošću.

Opisana heuristika navođenja slučajne pretrage ne može se uzeti kao opšte rešenja za sve optimizacione probleme. U slučaju složenijih problema, što je najčešće slučaj sa problemima iz realnog sveta, ova metoda bi se najčešće zaglavljivala u lokalnom minimumu (maksimumu). Jedan od primera koji može da posluži za ilustraciju gde ova metoda ne bi bila uspešna je standardna funkcija na kojoj se optimizacioni algoritmi testiraju - Rastrigin funkcija prikazana na slici 26. Ova funkcija je zasnovana na funkciji sfere sa dodatom kosinusnom modulacijom kako bi se napravili lokalni minimumi. Funkcija je definisana na intervalu $[-5.12, 5.12]$ sledećom formulom:

$$f(x) = 10n + \sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i)] \quad (33)$$

gde je n dimenzija problema.

Za ovako kompleksnu funkciju, jednostavno navođenje nizbrdo bi dovelo do zaglavljivanja u lokalnim optimumima. Kako bi se to izbeglo, potrebno je pored navođenja nizbrdo, pronaći način da se pretražuju i drugi delovi prostora pretrage. Moguće je naći heuristiku koja bi rešavala i ovaj problem, ali onda bi se mogao naći kompleksniji primer gde ni ta nova heuristika ne bi pronalazila dobra rešenja. Dolazi



Slika 26: *Rastrigin funkcija*

se do zaključka da je slučajnu pretragu praktično neophodno voditi na neki način, ali da nema univerzalnog načina kako je treba voditi. Ovde se dolazi do, u matematici, neobične ideje da se za vođenje slučajne pretrage simuliraju neki uspešni procesi iz prirode. Početna ideja bila je simulacija procesa evolucije živih organizama u prirodi kroz generisanje potomstva i preživljavanje najprilagođenijih koja se pokazala kao vrlo uspešna i dala je podstrek konstruisanju drugih sličnih algoritama, što je tema poglavlja 7.

5.1 Matematička formulacija problema globalne optimizacije

Brojni teški optimizacioni problemi javljaju se kao problemi diskretne optimizacije gde je broj mogućih rešenja eksponencijalan u odnosu na dimenziju problema i svi su oni na neki način ekvivalentni problemu putujućeg trgovca. U praksi su verovatno češći kontinualni optimizacioni problemi gde treba naći minimum (ili maksimum) neke n -dimenzionalne kontinualne funkcije, a od ovakvih problema u klasu teških ulaze oni gde je broj lokalnih minimuma eksponencijalan u odnosu na dimenziju problema. Na taj način, iako se radi o problemima kontinualne optimizacije, za koje postoje efikasni deterministički algoritmi. ovakvi problemi ekvivale problemu putujućeg trgovca jer je bez obzira na mogućnost pronala bilo kod lokalnog, potrebno je pretažiti eksponencijalno mnogo lokalnih optimuma da bi se pronašao globalni,

Kompleksnost optimizacionih problema zavisi od tipa funkcije koju je potrebno

optimizovati, ograničenja i promenjivih odlučivanja (engl. decision variables).

Problem globalne optimizacije može se definisati kao minimizacija (ili maksimizacija) n -dimenzionalne funkciju cilja f (koriste se i termini objektna funkcija i fitnes funkcija). Problem minimizacije se matematički se definiše kao:

$$\min_{x \in R^n} f(x), \quad x = (x_1, x_2, \dots, x_n) \quad (34)$$

tako da važi:

$$\begin{aligned} g_j(k) &\leq 0, & j &\in [1, k] \\ h_i(x) &= 0, & i &\in [1, m] \end{aligned}$$

U ovakvoj formulaciji, R^n predstavlja prostor pretrage funkcije f . Sva moguća rešenja su $x \in R^n$. Parametar n predstavlja dimenziju prostora pretrage odnosno broj varijabli odlučivanja. Funkcije h_i i g_j predstavljaju ograničenja. U slučaju da je $m = k = 0$, radi se o problemu optimizacije bez ograničenja (engl. unconstrained optimization problem). Problemi optimizacije bez ograničenja mogu imati definisane granice pretrage. U tom slučaju rešenja $x \in S$, gde $S \in R^n$ predstavlja prostor pretrage, n -dimenzionalnu hiperkocku ograničenu donjim i gornjim granicama:

$$lb_i \leq x_i \leq ub_i, \quad i \in [1, n]. \quad (35)$$

Funkcije ograničenja sužavaju prostor pretrage i na taj način neka od rešenja $x \in R^n$ postaju nedopustiva i globalni optimum se traži samo među dopustivim rešenjima (engl. feasible solutions). Osnovne verzije algoritama za rešavanje problema optimizacije sa ograničenjima najčešće ne koriste metode za razmatranje ograničenja već se obično primenjuju tehnike za poboljšanje i usmeravanje procesa pretraživanja prema domenu dopustivih rešenja. Ograničenja jednakosti (funkcije h_i u formuli (34)) čine optimizaciju znatno težom pošto prostor pretrage postaje veoma mali u poređenju sa celim prostorom pretrage i često je vrlo teško pronaći bilo koje dopustivo rešenje. Da bi se rešio takav problem, ograničenja jednakosti su zamenjena sa ograničenjima nejednakosti:

$$|h(x)| - \nu \leq 0, \tag{36}$$


gde je ν mala tolerancija kršenja ograničenja. Obično je na početku algoritma ta tolerancija veća i polako se smanjuje kroz iteracije.

6 Metaheuristike

Rešavanje NP teških problem u polinomijalnom vremenu nije moguće egzaktnim metodama te je potrebno koristiti heurističke algoritme. Heuristički algoritmi za rešavanje optimizacionih problema ne mogu garantovati pronalazak globalnog optima ali bi trebalo da mogu da pronađu dovoljno kvalitetno rešenje u razumnom vremenskom periodu.

Heuristički algoritmi bi trebalo da zadovoljavaju određene uslove kao što su generisanje rezultata bliskog optimalnom rešenju sa velikom verovatnoćom i to u razumnom vremenskom periodu a sa druge strane bi verovatnoća dobijanja lošeg rešenja trebala da bude mala [58].

Klasifikacija heuristika je veoma nezahvalan posao obzirom na njihov broj i raznovrsnost. U literaturi se mogu pronaći različite klasifikacije a jedna od njih je predstavljena na slici 27.



Slika 27: Klasifikacija metoda optimizacije [81]

Kako bi se ilustrovala raznovrsnost klasifikacije heuristika a time i samih heurističkih metoda data je još jedna podela u nastavku [58]:

- dekompozicione heurističke metode (engl. decomposition methods)
- induktivne heurističke metode (engl. inductive methods)
- redukcione heurističke metode (engl. reduction methods)

- konstruktivne heurističke metode (engl. constructive methods)
- heurističke metode lokalne pretrage (engl. local search methods)


Uobičajeno pitanje koje se postavlja je: koji je najbolji algoritam optimizacije? To je jednostavno pitanje, ali nažalost nema jednostavnog odgovora. Mnogo je razloga zašto se ne može dati jednostavan odgovor. Jedan od razloga je što složenost i raznolikost problema u stvarnom svetu često znače da se neki problemi lakše rešavaju, dok drugi mogu biti izuzetno teški i komplikovani. Drugi razlog je takozvana *no free lunch* teorema (NFL) koja kaže da ne postoji univerzalni algoritam za sve probleme. Teorema kaže da ako algoritam A nadmaši algoritam B za neke optimizacione funkcije, onda će B nadmašiti A za druge funkcije. Drugim rečima, ako se uporede sa svim mogućim funkcijskim prostorima, oba algoritma A i B će u proseku jednako dobro funkcionisati. To znači da ne postoje univerzalno bolji algoritmi. Na osnovu iskustava, neki algoritmi nadmašuju druge za date tipove problema optimizacije. Dakle, glavni cilj bi bio da se izabere najprikladniji algoritam za dati problem, ili da se dizajniraju bolji algoritmi za većinu tipova problema, ne nužno za sve.

Kako su se heuristički algoritmi pokazali kao pogodne metode rešavanja velikog broja optimizacionih problema, prirodno je bilo da su privukli veliku pažnju istraživača. Intenzivno razvijanje i istraživanje heurističkih metoda je rezultiralo pojavom metaheuristika.

U literaturi se mogu naći različite definicije metaheuristika. Fred Glover je prvi upotrebio izraz *metaheuristika* 1986. godine u radu gde je predložio danas dobro poznati algoritam tabu pretraga (engl. tabu search) [31]. Jedna od definicija metaheuristika je da one predstavljaju viši nivo opštih metodologija koje se mogu koristiti kao strategije koje usmeravaju pravljenje heuristike za rešavanje posmatranog optimizacionog problema [81].

Jedna od najgrubljih podela metaheuristika je prikazana na slici 27. Pored podele na metaheuristike zasnovanih na populaciji (engl. population-based) i metaheuristike zasnovanih na poboljšanju jednog rešenja (engl. single-based metaheuristics), često se u literaturi izdvajaju hibridizacije i memetičke metaheuristike, paralelne metaheuristike, metaheuristike inspirisane prirodom, metaheuristike koje koriste memoriju i one bez memorije, determinističke, stohastičke, iterativne, pohlepne metaheuristike,

itd. Kompleksnost klasifikacije metaheuristika je najbolje ilustrovana na slici 28 [101] gde i dalje nisu obuhvaćene sve podele koje se mogu naći u literaturi.



Slika 28: Klasifikacija metaheuristika

Iako postoji veliki broj metaheuristika koje se zasnivaju na različitim principima, ključ uspeha je u dobro definisanim kriterijumima pretrage prostora rešenja. Sve metaheuristike u nekoj meri imaju dva načina pretrage: eksploraciju prostora rešenja i eksploataciju pronađenog dobrog rešenja. Eksploatacija ili intenzifikacija se koristi za fino pretraživanje obećavajuće oblasti, odnosno oblasti oko do sada pronađenih najboljih rešenja. Eksploracija ili diverzifikacija služi za istraživanje prostora pretrage i za generisanje različitih rešenja kako bi se izbeglo zaglavljivanje u lokalnom optimumu. Previše eksploatacije će ubrzati proces optimizacije, ali dovodi do prevremene konvergencije. Sa druge strane, prevelika eksploracija će povećati verovatnoću pronalaženja istinske optimalnosti na globalnom nivou, ali će usporiti

proces konvergencije. Dakle, potrebno je da postoji dobra ravnoteža ili kompromis između eksploatacije i eksploracije.

7 Algoritmi inspirisani prirodom

U potrazi za rešenjima teških optimizacionih problema, kao ideja za vođenje slučajne pretrage, došlo se na ideju da se simuliraju različiti procesi iz prirode. Priroda daje inspiraciju istraživačima u oblasti računarstva na mnogo načina.

Istorija algoritama inspirisanih prirodom je duga više od pola veka. Značajan i ubrzan razvoj je prisutan poslednjih 20 godina. Od pojave evolutivnih strategija šezdesetih godina i razvoja genetskog algoritma (engl. genetic algorithm, GA) sedamdesetih godina prošlog veka [36], počelo je zlatno doba sa velikim napretkom u rešavanju teških problema optimizacije. Prvo, 1992. godine, Marko Dorigo (engl. Marco Dorigo) je opisao svoj inovativni rad na optimizaciji kolonije mrava (engl. ant colony optimization, ACO) u svojoj doktorskoj tezi [23], a iste godine, J.R. Koza je objavio istraživanje o genetičkom programiranju [48]. Nakon toga, 1995. godine, Džejms Kenedi (engl. James Kennedy) i Rasel Eberhart (engl. Russel Eberhart) razvili su optimizaciju rojem čestica (engl. particle swarm optimization, PSO) [46], čime se u suštini otvorilo novo istraživačko polje, sada poznato kao algoritmi inteligencije rojeva (engl. swarm intelligence algorithms, SI). Nakon toga 1996. i 1997. godine, Rainer Storn i Kenet Prajs (engl. Kenneth Price) objavili su rad koji predlaže algoritam diferencijalne evolucije [77].

Odlična efikasnost algoritama inspirisanim prirodom je često iznenađujuća, jer ti naizgled jednostavni algoritmi u praksi daju zapanjujuće dobre rezultate. Na primer, za multimodalne optimizacione probleme, mnogi tradicionalni algoritmi ne rade, dok novi algoritmi kao što je diferencijalna evolucija (engl. differential evolution, DE) i algoritam svica (engl. firefly algorithm, FA) mogu biti veoma dobri u praksi, iako možda nismo u potpunosti razumeli osnovne mehanizme algoritama [108]. Sve veća popularnost bio-inspirisane metaheuristike i inteligencije roja (SI) privukla je veliku pažnju u inženjerstvu i industriji. Postoje mnogi razlozi za takvu popularnost, i ovde govorimo o tri faktora: jednostavnost, fleksibilnost i ergodičnost. Prvo, većina algoritama inspirisanih prirodom su jednostavni u smislu da su jednostavni za implementaciju i njihova složenost je relativno niska. U većini programskih jezika, jezgro algoritma se može implementirati sa stotinu linija koda. Drugo, ovi algoritmi, iako relativno jednostavni, su dovoljno fleksibilni da se bave širokim spektrom problema optimizacije, uključujući i one koji nisu rešivi konvencionalnim algoritmima.

Treće, algoritmi inspirirani prirodom često imaju visok stepen ergodičnosti u smislu da mogu da pretražuju multimodalni prostor rešenja sa dovoljnom raznolikošću i sposobnošću da izbegnu bilo koji lokalni optimum [108].

Algoritmi inspirisani prirodom se najgrublje mogu podeliti u dve kategorije: evolutivni algoritmi i algoritmi inteligencije rojeva.

7.1 Evolutivni algoritmi


Evolutivni algoritmi simuliraju proces evolucije i uključuje algoritme kao što su genetski algoritam, genetsko programiranje [48], evolutivno programiranje [4], diferencijalna evolucija [78] i drugi. Biološki proces evolucije je poslužio istraživačima kao inspiracija za evolutivne algoritme koje karakterišu operacije poput reprodukcije, mutacije, kombinovanja i selekcije. Generalni tok EA je prikazan algoritmom 1 i šematski na slici 29.

Algorithm 1 Opšti pseudo kod evolutivnih algoritama

```

inicijalizacija populacije
repeat
    odabir roditelja za ukrštanje
    ukrštanje parova roditelja kako bi se generisali potomci
    mutacija potomaka
    evaluacija podobnosti potomaka
    proces selekcije jedinki za sledeću generaciju
until nije zadovoljen kriterijum zaustavljanja
kraj

```



Slika 29: Proces evolutivnih algoritama

Jedna od najstarijih i najpoznatijih evolutivnih metaheuristika je genetski algo-

ritam (engl. genetic algorithm, GA). GA je moćan metod optimizacije zasnovan na principima genetike i prirodne selekcije [36]. Holand je prvi koristio ukrštanje i rekombinaciju, mutaciju i selekciju u proučavanju adaptivnih i veštačkih sistema. Ovi genetski operatori čine suštinski deo rešavanja problema. Do sada su razvijene mnoge varijante GA i primenjene na širok spektar problema optimizacije. Jedna od glavnih prednosti je da je GA metoda koja ne koristi gradijent i predstavlja fleksibilnu metodu za rešavanje različitih tipova problema optimizacije gde funkcija cilja može biti stacionarna ili nestacionarna, linearna ili nelinearna, kontinuirana ili diskretna, ili sa slučajnim šumom. U GA, populacija može istovremeno pronaći prostor za pretraživanje u mnogim pravcima, jer se brojni potomci u populaciji ponašaju kao nezavisni agenti. Dalje, različiti parametri i grupe kodiranih nizova mogu se manipulirati u isto vreme.

Diferencijalna evolucija (engl. differential evolution, DE) je razvijena od strane Storn i Price 1997. godine [77]. To je evolutivni algoritam koji se može smatrati daljnjim razvojem genetskih algoritama. Predstavlja stohastički algoritam pretrage sa samo-organizujućom tendencijom i ne koristi informacije o derivatima. Izvršava operacije nad svakom komponentom (ili svakom dimenzijom rešenja). Rešenja su predstavljena u terminima vektora, a zatim su mutacije i ukrštanja izvršeni korišćenjem ovih vektora. Na primer, u genetskim algoritmima, mutacija se sprovodi na jednom ili na više mesta hromozoma, dok se u diferencijalnoj evoluciji koristi vektor razlike dva nasumično izabrana vektora za menjanje postojećeg vektora. Takva vektorizovana mutacija može se posmatrati kao samoorganizujuća pretraga, usmerena ka optimalnosti. Ova vrsta mutacije se sprovodi na svakom populacionom vektoru, i stoga se može očekivati da bude efikasnija. Slično tome, ukrštanje je takođe vektorska razmena hromozoma ili vektorskih segmenata.

7.2 Algoritmi inteligencije rojeva

Jedan izvor inspiracije iz prirode za definisanje optimizacionih algoritama je način na koji se prirodni organizmi ponašaju u grupama kao na primer roj mrava, roj pčela, kolonija bakterija ili jato ptica. U ovim i sličnim slučajevima, biolozi tvrde, a i često se lično može uveriti, da grupa jedinki u prirodi pokazuje ponašanje koje pojedini članovi nemaju. Drugim rečima, ako posmatramo grupu, odnosno

roj, kao pojedinaca, čini se da je roj inteligentniji od bilo kojeg pojedinca u njemu. Ovo zapažanje je seme jedne grupe koncepata i algoritama optimizacije inspirisane prirodom, algoritama inteligencije rojeva.

Ako u prirodi tražimo scenario u kojem kolekcija agenata pokazuje ponašanje koje pojedinci nemaju, lako ćemo pronaći brojne primere. Inteligencija roja se odnosi na to kako pojedinci sarađuju (svesno ili ne) u postizanju određenog cilja. Na primer, mravi pronalaze najkraći put između svog gnezda i dobrog izvora hrane, ili pčele pronalaze najbolje izvore nektara u okolini svoje košnice, itd. Ovi i slični prirodni procesi direktno su doveli do grupe algoritama koji su se pokazali kao veoma značajan doprinos nauci.

Algoritmi inteligencije rojeva simuliraju kolektivno ponašanje mnoštva agenata od kojih svaki prati jednostavna pravila i komunicira sa ostalim agentima iz roja. Iako su agenti pojedinačno veoma primitivni i jednostavni, ceo roj može pokazati izvanrednu kolektivnu inteligenciju.

Naučnici su inspirisani sveukupnim procesima prirode koja pokazuju *više od zbira ponašanja delova* što i potvrđuje veliki broj algoritama. Međutim, ako se fokusira na specifičan koncept inteligencije roja i pokuša da se definiše, rezultat bi mogao biti sledeći:

To je korisno ponašanje koje proizilazi iz zajedničkih napora grupe pojedinačnih agenata:

- u kojima su pojedinačni ageniti uglavnom homogeni;
- u kojima pojedinačni agenti deluju asinhrono paralelno;
- u kojoj je centralna kontrola mala ili nikakva;
- u kojoj komunikacija između agenata u velikoj meri utiče na neki oblik stigme;
- u kojima je *korisno ponašanje* relativno jednostavno (pronalaženje dobrog mesta za hranu, ili izgradnju gnezda, pisanje simfonije, preživljavanje dugi niz godina u dinamičnom okruženju, itd).

Među najstarijim algoritmima inteligencije rojeva su optimizacija rojevima čestica (engl. particle swarm optimization, PSO) [46] i optimizacija mravljim kolonijama (engl. ant colony optimization, ACO) [24]. Danas se mogu pronaći mnogi algoritama

inteligencije rojeva kao što su algoritam slepog miša [105], algoritam vatrometa [82], algoritam svica [103], brain storm optimizacioni algoritam [71], algoritam naseljavanja slonova [98], i mnogi drugi. Neki od ovih algoritama su korišćeni u ovom radu pa će biti detaljnije opisan.

7.2.1 Optimizacija rojem čestica

Algoritam optimizacije rojem čestica (engl. particle swarm optimization, PSO), inspirisan ponašanjem jata ptica, prvobitno su predložili Džejms Kenedi (engl. James Kennedy) i Rasel Eberhart (engl. Russel Eberhart) 1995. godine [46].

Standardni PSO algoritam inicijalizuje populaciju (roj) slučajnih potencijalnih rešenja (čestica). Svaka čestica se iterativno kreće kroz prostor za pretraživanje i privlači je položaj najboljeg rešenja koje je istorijski (od početka algoritma) postignut samom česticom (lokalno najbolje) i najboljim rešenjem među ostalim česticama (globalni najbolji). Za razliku od genetskih operatora koji podjednako deluju na sva rešenja, u PSO svaka čestica prilagođava svoj let u skladu sa sopstvenim iskustvom letenja i letačkim iskustvom drugih ptica iz jata.

U originalnom PSO algoritmu, svaka jedinka je definisana svojom pozicijom, pravcem i brzinom kretanja. Pozicija svake jedinke se menja u svakoj iteraciji po sledećim formulama:

$$\mathbf{x}_i^{t+1} = \mathbf{x}_i^t + \mathbf{v}_i^{t+1} \quad (37)$$

gde je $\mathbf{x}_i^t$ trenutna pozicija, a $\mathbf{x}_i^{t+1}$ nova pozicija jedinke. Vektor $\mathbf{v}_i^{t+1}$ predstavlja brzinu kretanja. Ukoliko g^* predstavlja globalno najbolje rešenje a sa $\mathbf{x}_i^{*(t)}$ se označava istorijski najbolje rešenje jedinke i onda se brzina prepačunava na sledeći način:

$$\mathbf{v}_i^{t+1} = \mathbf{v}_i^t + \alpha \cdot \boldsymbol{\theta}_1 \odot (\mathbf{g}^* - \mathbf{x}_i^t) + \beta \cdot \boldsymbol{\theta}_2 \odot (\mathbf{x}_i^{*(t)} - \mathbf{x}_i^t) \quad (38)$$

gde θ_1 i θ_2 predstavljaju vektore sa komponentama generisanim uniformno iz intervala $[0, 1]$, w_1 i w_2 težinski faktori koji su parametri algoritma, a $\odot$ označava množenje dva vektora po komponentama.

Dobro odabrani težinski faktori mogu stabilizovati kretanje jata i ubrzati kon-

vergenciju. Koristeći linearno opadajuću inercijsku težinu, PSO nema sposobnost globalne pretrage. Ipak, rezultati prikazani u literaturi ilustruju da se korišćenjem linearno opadajuće težinske inercije, performanse PSO algoritma mogu značajno poboljšati.

7.2.2 Algoritam slepog miša

U proteklih nekoliko godina predložene su mnoge metaheuristike zasnovane na populaciji. Jedan od njih je algoritam slepog miša (engl. bat algorithm, BA) koji je uveo Yang u 2010. godini [105]. Ovaj algoritam je inspirisan ponašanjem slepih miševa. Kao osnova za algoritam koristi se ehologacija koju koriste slepi miševi. Oni koriste ehologaciju kako bi otkrili plen i izbegli prepreke. Oni emituju zvučne impulse i kreću se kroz prostor koristeći vremensko kašnjenje od emisije do refleksije.

Algoritam slepog miša je često izbor za rešavanje raznih problema optimizacije. Korišćen je za multi-objektnu optimizaciju (optimizaciju sa više funkcija cilja) [106], probleme optimizacije sa ograničenjem [29], inženjerske probleme optimizacije [107], itd. Tokom proteklih nekoliko godina, istraživači su takođe predložili mnoga poboljšanja, adaptacije za konkretne probleme i hibridizacije algoritma slepog miša. Hibridizacija algoritma je predložena u [28] i [99]. U [110] i [2], algoritma slepog miša korišćen je za obradu slika, dok je u citatu [93] korišćen za planiranje RFID mreže. U radu [60] razvijen je binarni algoritam slepog miša za izbor karakteristika u klasifikaciji. U [91] korišćen je za treniranje neuronskih mreža.

Prirodno ponašanje slepih miševa je pojednostavljeno kako bi se definisao algoritam slepog miša. Algoritam slepog miša je populacioni algoritam tako da se populacija slepih miševa koristi za traženje najboljeg rešenja. U početku je potrebno inicijalizovati tu populaciju. Svaki slepi miš ima svoje znanje koje deli sa drugim slepim miševima iz populacije. Takođe, svaki slepi miš koristi znanje drugih slepih miševa. Svaki član populacije je predstavljen svojom lokacijom x_i^t , brzinom v_i^t , frekvencijom f_i^t , glasnošću A_i^t i brzinom pulsa r_i^t u D -dimenzionalnom prostoru pretrage. Inicijalno se parametri postavljaju na slučajane vrednosti. Nakon inicijalizacije, novi parametri su definisani na osnovu prethodnih. Sledeća jednačina se koristi za izračunavanje novog rešenja i brzine [105]:

$$f_i = f_{min} + (f_{max} - f_{min})\beta \quad (39)$$

$$v_i^t = v_i^{t-1} + (x_* - x_i^{t-1})f_i \quad (40)$$

$$x_i^t = x_i^{t-1} + v_i^t \quad (41)$$

gde β predstavlja slučajan vektor generisan na intervalu $[0, 1]$ i x_* je trenutno globalno najbolje rešenje. Najbolje rešenje je utvrđeno nakon poređenja svih rešenja populacije.

Frekvencija svakog slepog miša se u početku nasumično dodjeljuje iz intervala $[f_{min}, f_{max}]$, gde su f_{min} i f_{max} početni parametri algoritma. Ove parametre treba prilagoditi za svaki problem.

Za lokalno pretraživanje ili eksploataciju koristi se slučajan hod (engl. random walk) sa direktnom eksploatacijom. Tekuće rešenje je modifikovano prema jednačini:

$$x_{new} = x_* + \epsilon * A_t \quad (42)$$

gde je A_t prosečna glasnoća svih slepih miševa u trenutnoj iteraciji i ϵ je slučajni broj iz opsega $[-1, 1]$. Parametar ϵ određuje intenzitet i pravac slučajnog hoda. Veoma važnu ulogu u lokalnoj pretrazi ima brzina pulsa slepog miša. Kako je slepi miš bliži plenu, glasnost se smanjuje dok se brzina pulsa povećava. Brzina pulsa je definisana u određenom opsegu. Opseg može biti od 0 do 1, gde 0 znači da uopšte nema emisije, dok 1 znači maksimalno emitovanje [105]. Promena glasnoće i brzine pulsa definisane su sledećim jednačinama:

$$A_i^t = \alpha A_i^{t-1} \quad (43)$$

$$r_i^t = r_i^0(1 - e^{-\gamma t}) \quad (44)$$

gde su α i γ konstante. Vrednosti ova dva parametra imaju veliki uticaj na brzinu konvergencije i kvalitet konačnog rešenja. U zavisnosti od problema koji treba rešiti, različite vrednosti za ove parametre će dati bolje rezultate. Originalni algoritam slebrog miša opisan u ovom odeljku rezimiran je u algoritmu 2.

Algorithm 2 Pseudo kod algoritma slepog miša

[105]

```
Definisati objektu funkciju  $f(x)$ ,  $x = (x_1, x_2, \dots, x_d)^T$   
Inicijalizacija populacija  $x_i$ , ( $i = 1, 2, \dots, n$ ) i  $v_i$   
Definisati frekvenciju pulsa  $f_i$  na poziciji  $x_i$   
Inicijalizacija brzine pulsa  $r_i$  i glasnoću  $A_i$   
while  $t < IN$  do  
    Generisati nova rešenja podešavanjem frekvencije i preračunavanjem brzine i  
    lokacije korišćenjem jednačina (39) - (41)  
    if  $rand > r_i$  then  
        Pronađi najbolje rešenje u populaciji  
        Generiši novo rešenje u okolini najboljeg rešenja  
    end if  
    Generiši novo rešenje slučajnim hodom (random walk)  
    if  $rand < A_i$  and  $f(x_i) < f(x_*)$  then  
        Prihvati nova rešenja  
        Uvećaj  $r_i$  i umanji  $A_i$   
    end if  
    Rangiraj sva rešenja populacije i pronadi trenutno najbolje rešenje  $x_*$   
end while
```

7.2.3 Algoritam vatrometa

Algoritam vatrometa (engl. fireworks algorithm, FWA) je metaheuristički algoritam koji je inspirisan eksplozijom vatrometa. Predložili su ga Tan i Zhu 2010. godine u radu [82] gde je upoređen sa standardnim PSO algoritmom [82].

Inspiracija za FWA je eksplozija vatrometa koja se može posmatrati kao pretraga prostora oko specifične tačke gde se vatromet nalazi koristeći varnice koje su nastale u eksploziji. Kada se zapali vatromet, puno varnica ispunjava prostor oko njega. U blizini centra eksplozije nastaju brojne varnice i proređuju se zajedno sa udaljenošću. Broj generisanih varnica zavisi od kvaliteta vatrometa. FWA je iterativni algoritam i svaka iteracija simulira jednu eksploziju vatrometa na n lokacija. Pre nego svake iteracije se bira novih n lokacija za vatromete među lokacijama generisanih varnica i trenutnih lokacija vatrometa.

Za FWA su važna dva parametra. Prvi je broj varnica a drugi je koeficijent amplitude eksplozije:

$$s_i = m \frac{Y_{max} - f(x_i) + \varepsilon}{\sum_{i=1}^N (Y_{max} - f(x_i)) + \varepsilon} \quad (45)$$

U ovoj formuli, s_i je broj varnica generisanih iz i -tog vatrometa, m je konstanta

koja kontroliše ukupan broj generisanih varnica u jednoj iteraciji, Y_{max} predstavlja najgoru vrednost funkcije cilja u trenutnoj iteraciji (špd pretpostavkom da se radi o problemu minimizacije) i $f(x_i)$ je vrednost funkcije cilja za vektor definisan pozicijom vatrometa x_i . Parametar ε se koristi za sprečavanje deljenja nulom.

Neophodno je definisati donju i gornju granicu broja varnica i to je učinjeno na sledeći način [82]:

$$\hat{s}_i = \begin{cases} \text{round}(\alpha m), & \text{if } s_i < \alpha m \\ \text{round}(\beta m), & \text{if } s_i > \beta m, \\ \text{round}(s_i), & \text{otherwise} \end{cases} \quad \alpha < \beta < 1 \quad (46)$$

gde su α i β konstante i predstavljaju parametre algoritma.

Koeficijent amplitude je definisan kao:

$$A_i = \hat{A} \frac{f(x_i) - Y_{min} + \varepsilon}{\sum_{i=1}^N (f(x_i) - Y_{min}) + \varepsilon} \quad (47)$$

gde A_i predstavlja amplitudu za generisanje varnica pojedinačnog vatrometa x_i , $\hat{A}$ je konstanta za kontrolisanje amplitude. Vatromet sa boljom vrednošću funkcije cilja će imati manju amplitudu eksplozije, dok vatromet sa lošijom vrednošću funkcije cilja ima veću amplitudu. Najbolja vrednost funkcije cilja u populaciji je označena sa Y_{min} .

Eksplozija utiče na z dimenzija izabranih na slučajan način. Broj dimenzija koje će biti promenjene se određuje pomoću:

$$z = \text{round}(d\chi) \quad (48)$$

gde d predstavlja dimenziju prostora pretrage i χ slučajni broj iz uniformne raspodele između 0 i 1.

Kada se generišu varnice, neke od njih mogu biti generisane izvan prostora pretrage. Postoji strategija mapiranja koja zadržava varnice unutar prostora pretrage.

Pre nove iteracija, potrebno je da se izabere varnica sa najboljom vrednošću funkcije cilja i ona se prenosi i u sledeću iteraciju. Ostalih $(n - 1)$ vatrometa se biraju na osnovu njihove udaljenosti od drugih lokacija kako bi se zadržala raznovrsnost rešenja [82]. Udaljenost između pozicije x_i i drugih lokacija izračunava se kao:

$$R(x_i) = \sum_{j \in K} d(x_i, x_j) = \sum_{j \in K} \|x_i - x_j\| \quad (49)$$

gde je K skup svih trenutnih lokacija vatrometa i varnica.

Autori FWA su uočili određene nedostatke, te su predložili drugu verziju koju su nazvali poboljšani FWA (engl. enhanced fireworks algorithm, EFWA). Predstavili su pet glavnih poboljšanja FWA [112]:

1. novu proveru minimalne amplitude eksplozije,
2. novi operator za generisanje eksplozije (varnica),
3. novu strategiju mapiranja varnica koje su generisane izvan prostora pretrage,
4. novi operator za generisanje Gausovih varnica,
5. novi operator za odabir populacije za sledeću iteraciju.

Problem sa starom jednačinom za izračunavanje amplitude eksplozije se pojavljuje kada je optimalna vrednost funkcije cilja jednaka ili blizu nule. U tom slučaju, amplituda eksplozije vatrometa će biti veoma mala, tako da će varnice biti locirane na istom ili skoro istom položaju kao i sam vatromet. Kao rezultat toga, moguće je da se najbolje rešenje u okolini jednog vatrometa ne može pronaći sve dok neki drugi vatromet ne pronađe bolji položaj. Autori su predložili donju granicu za amplitudu eksplozije, A_{min} , koja zavisi od iteracije algoritma. U prvim iteracijama A_{min} uzima veću vrednost, ali sa povećanjem broja iteracija, A_{min} se smanjuje.

Vrednost od A_{min} se izračunava u svakoj iteraciji. Jedan pristup za određivanje nove vrednosti zasniva se na jednačini:

$$A_i = \begin{cases} A_{min} & \text{if } A_i < A_{min}, \\ A_i & \text{otherwise} \end{cases} \quad (50)$$

gde je:

$$A_{min}(t) = A_{init} - \frac{A_{init} - A_{final}}{evals_{max}} * t \quad (51)$$

Parametar t se odnosi na broj evaluacija funkcije cilja na početku trenutne iteracije, a $evals_{max}$ je maksimalni broj evaluacija. A_{init} i A_{final} su početna i krajnja minimalna amplituda eksplozije.

Sledeća modifikacija se odnosi na operatera za generisanje varnica. U originalnom FWA algoritmu se pomeraj varnice u odnosu na vatromet računao dodavajući istu vrednost na sve odabrane dimenzije što ograničava potragu globalnog minimuma. Autori su predložili da se za svaku izabranu dimenziju izračuna različita vrednost, tako da se u EFWA izračunava različit pomeraj po svakoj dimenziji.

U EFWA, varnice će biti mapirane na novu lokaciju prema jednačini:

$$x_{ik} = X_{LB,k} + |x_{ik}| \%(X_{UB,k} - X_{LB,k}) \quad (52)$$

gde $X_{LB,k}$ i $X_{UB,k}$ označavaju gornju i donju granicu pretrage dok k označava dimenziju mapiranja.

Takođe, dodat je i novi operator za generisanje takozvanih Gausovih varnica:

$$x_i = X_i + (X_B - X_i) \times e \quad (53)$$

gde je X_b trenutno najbolje rešenje, a e je slučajan broj iz Gausove raspodele $\mathcal{N}(0, 1)$.

Iako EFWA predstavlja poboljšanje originalnog FWA, razvoj ovog algoritma nije tu stao. Jedan od sledećih značajnijih verzija je vođeni algoritam vatrometa (engl. guided fireworks algorithm, GFWA). Ova verzija je predložena od strane Li, Zheng i Tan 2017. godine [53]. Da bi se dodatno poboljšao algoritam, korišćene su informacije o funkciji cilja za konstrukciju vektora vođenja ka obećavajućim pravcima. Kreirani vektor se dodaje vektoru rešenja čime se generiše elitno rešenje odnosno vodeća varnica (engl. guided spark). Vođeni algoritam vatrometa je opisan u nastavku. Broj varnica za svaki vatromet x_i se izračunava kao:

$$\lambda_i = \hat{\lambda} \frac{\max_j (f(x_j)) - f(x_i)}{\sum_{j=1}^n (\max_k (f(x_k)) - f(x_i))}, \quad (54)$$

gde $\hat{\lambda}$ predstavlja parametar koji kontroliše ukupan broj varnica generisanih strane svih n vatrometa, $y_{max} = \max(f(x_i))$ ($i = 1, 2, \dots, n$) predstavlja najgore rešenje u populaciji.

Amplituda eksplozije definisana je sledećom jednačinom:

$$A_i = \hat{A} \cdot \frac{f(x_i) - y_{min} + \eta}{\sum_{i=1}^n (f(x_i) - y_{min}) + \eta}, \quad (55)$$

gde $\hat{A}$ definiše najveću vrednost amplitude eksplozije a $y_{min} = \min(f(x_i), i = 1, 2, \dots, n)$ predstavlja najbolje rešenje u populaciji od n vatrometa.

Za vatromet sa najboljom vrednošću funkcije cilja, nazvanom jezgro vatromet (engl. core firework, CF) amplituda eksplozije podešena je prema sledećoj jednačini [53]:

$$A_{CF}(t) = \begin{cases} A_{CF}(1) & \text{if } f(X_{CF}(t)) = f(X_{CF}(t-1)), \\ C_r A_{CF}(t-1) & \text{if } f(X_{CF}(t)) = f(X_{CF}(t-1)), \\ C_a A_{CF}(t-1) & \text{if } f(X_{CF}(t)) < f(X_{CF}(t-1)) \end{cases} \quad (56)$$

gde t predstavlja broj trenutne generacije, dok su $C_a > 1$ i $C_r < 1$ konstante.

U svakoj generaciji, vođena varnica (engl. guided spark, GS) je generisana za svaki vatromet. Položaj GS, G_i za vatromet X_i određen je sledećim algoritmom [53]:

Algorithm 3 Generisanje vođene varnice za X_i [53]

Require: X_i, s_{ij}, λ_i i σ

Sortiraj varnice prema vrednosti fitnes funkcije $f(s_{ij})$ u rastućem poretku.

$$\Delta_i \leftarrow \frac{1}{\sigma \lambda_i} (\sum_{j=1}^{\sigma \lambda_i} s_{ij} - \sum_{j=\lambda_i - \sigma \lambda_i + 1}^{\lambda_i} s_{ij})$$

$$G_i \leftarrow X_i + \Delta_i$$

return G_i

U algoritmu 4 je prikazan pseudo kod vođenog algoritma vatrometa:

Algorithm 4 Vođeni algoritam vatrometa [53]

Inicijalizacija μ rešenja (vatrometa) na slučajan način.

Evaluacija generisanih rešenja.

repeat

 Računanje λ_i prema jednačini 54

 Računanje A_i prema jednačinama 55 i 56

 Za svako rešenje, generisati λ_i varnica sa amplitudom A_i

 Za svako rešenje, generisati vođenu varnicu prema algoritmu 3

 Evaluacija svih generisanih rešenja u prethodnim koracima.

 Sačuvati najbolje rešenje za sledeću iteraciju.

 Nasumično odabrati još $\mu - 1$ rešenja za sledeću iteraciju.

until kriterijum zaustavljanja je zadovoljen.

return Najbolje rešenje i njegovu vrednost fitnes funkcije.

Najnovija verzija algoritma vatrometa je takozvani maksimalno pojednostavljeni (ogoljeni) algoritam vatrometa (engl. bare bone fireworks algorithm) [54]. Ovu verziju su predložili Li i Tan 2018. godine,

Za razliku od prethodnih verzija FWA, BBFWA koristi samo jedan vatromet koji proizvodi konstantan broj varnica oko sebe što je rezultiralo manjim vremenom izračunavanja. Eksploracija i eksploatacija su sprovedeni povećanjem i smanjenjem prostora oko najboljeg rešenja u kojem bi se generisala slučajna rešenja (varnice). U svakoj iteraciji BBFWA čuva samo najbolje rešenje za sledeću iteraciju. Veličina prostora za pretraživanje oko tog rešenja je regulisana sa dva parametra, C_a i C_r . Prvo rešenje se generiše na slučajan način i početna veličina prostora za pretraživanje oko njega je postavljena tako da pokriva celi prostor pretraga. Ako Lb i Ub predstavljaju donju i gornju granicu prostora za pretraživanje, onda se slučajna rešenja generišu u hiper-pravougaoniku čiji je centar najbolje rešenje, a veličina strane je $2 * A$ gde je početno $A = Ub - Lb$. U narednim iteracijama, veličina hiper-pravougaonika se menja za faktor $C_a > 1$ (povećava se) ako se pronade novo najbolje rešenje. Ako se pronade novo najbolje rešenje, to znači da prostor pretrage nije dovoljno istražen pa je potrebna šira pretraga. S druge strane, ako najbolje rešenje ostaje isto u dve iteracije, tada se veličina hiper-pravougaonika smanjuje za faktor $C_r < 1$ što omogućuje finu pretragu obećavajućeg područja.

Pseudo kod za BBFWA je prikazan algoritmom 5.

Algorithm 5 Maksimalno pojednostavljen algoritam vatrometa, BBFWA [54]

```

Generiši nasumično rešenje  $x \sim U(Lb, Ub)$ 
Evaluacija generisanog rešenja  $f(x)$ 
 $A = Ub - Lb$ 
repeat
  for  $i = 1$  do  $N$  do
    Generiši  $s_i \sim U(x - A, x + A)$ 
    Primeni operator mapiranja na  $s_i$ 
    Evaluacija generisanog rešenja  $f(s_i)$ 
  end for
  if  $\min_{i=1,2,\dots,N} (f(s_i)) < f(x)$  then
     $x = \operatorname{argmin}(f(s_i))$ 
     $A = C_a A$ 
  else
     $A = C_r A$ 
  end if
until kriterijum zaustavljanja je zadovoljen
return  $x$ 

```

7.2.4 Algoritam svica

Algoritam svica (engl. firefly algorithm, FA) koji je definisao Yang, 2010. godine [103], je inspirisan svetlosnom signalizacijom svitaca . Kretanje svitaca u populaciji je opisano ili pseudo-slučajnom putanjom ili je definisano svicima koji emituju jače svetlo, pri čemu je intenzitet svetslosti svakog svica proporcionalan sa kvalitetom vrednosti objektne funkcije.

U svakoj iteraciji se svitac pomera pod uticajem svetlosti i atraktivnosti drugih svitaca iz populacije. Kretanje svica može da se definisati sledećom jednačinom [104]:

$$x_i = x_i + \beta_0 e^{-\gamma r_{i,j}^2} (x_i - x_j) + \alpha \epsilon_i, \quad (57)$$

gde je x_i trenutna pozicija svica i , drugi sabirak predstavlja privlačnost svica j , parametar α je parametar slučajnosti i predstavlja parametar algoritma, dok je ϵ_i slučajan vektor sa vrednostima u intervalu između 0 i 1. Standardne vrednosti parametara β_0 i α su 1 i $\alpha \in [0, 1]$.

Privlačnost među svicima zavisi između ostalog i od parametra γ . Ovaj parametar ima je vrlo značajan za postizanje adekvatne konvergencije algoritma. Vrednost parametra γ je iz intervala $\gamma \in [0, \infty]$. Ovo predstavlja teorijsko ograničenje ali u praktičnim implementacijama njegova vrednost je definisana u intervalu od $[0.1, 10]$ [104].

U implementaciji FA je potrebno razmotriti dve bitne stvari: definisanje intenziteta svetlosti svakog svica i atraktivnosti odnosno odrediti privlačnost između dva svica u populaciji. Kao i kod svih drugih algoritama inspirisanih prirodom, procesi iz prirode su pojednostavljeniji, pa se u slučaju FA stepen privlačnosti svica definiše preko inteziteta njegove svetlosti koja je određena vrednošću objektne funkcije [104]. Takođe, za definisanje atraktivnosti svica β se pored kvaliteta vrednosti objektne funkcije koristi i relativna udaljenost između dva svica, svica i i j , označena sa r_{ij} .

Atraktivnost β svitaca se u većini slučajeva definiše kao neka monotono opadajuća funkcija, čiji je opšti oblik dat sledećom jednačinom [104]:

$$\beta_r = \beta_0 e^{-\gamma r^m}, m \geq 1. \quad (58)$$

Razdaljina između svica i i j koji predstavljaju redom potencijalna rešenja x_i i

x_j se računa kao Euklidska udaljenost [103]:

$$r_{ij} = ||x_i - x_j|| = \sqrt{\sum_{k=1}^D (x_{i,k} - x_{j,k})^2}, \quad (59)$$

gde $x_{i,k}$ je k -ti element u vektoru x_i , a D označava broj parametara problema optimizacije odnosno dimenziju vektora x_i .

Pseudo-kod FA prikazan je algoritmom 6.

Algorithm 6 Algoritam svica, FA [103]

```

Inicijalizacija populacije svitaca  $X_i, i = 1, 2, 3, \dots, N$ 
Generiši intenzitet svetlosti svica  $I_i$  u tački  $x_i$  na osnovu  $f(x)$ 
 $t = 0$ 
repeat
  for  $i = 1$  to  $(FN - 1)$  do
    for  $j = (i + 1)$  to  $FN$  do
      if  $I_j < I_i$  then
        približi svica  $j$  svicu  $i$ 
        evaluacija generisanog rešenja
        zadrži bolje rešenje i potencijalno ažuriraj intenzitet svetlosti
      end if
    end for
  end for
  Sačuvaj najbolje rešenje za sledeću iteraciju
  Nasumično pomeri ostala rešenja i sačuvaj za sledeću iteraciju
   $t++$ 
until  $t < IN$ 

```

U navedenom pseudo-kodu, FN označava veličinu populacije, IN je ukupan broj iteracija u jednom izvršavanju algoritma, a t je brojač trenutne iteracije.

7.2.5 Brain storm optimizacioni algoritam

Brain storm optimizacioni algoritam (engl. brain storm optimization, BSO) je algoritam inteligencije rojeva koji je predložio Yuhui Shi 2011. godini [71]. BSO je široko korišćen i primenjen na brojne probleme što je rezultiralo i različitim poboljšanim i modifikovanim verzijama [12], [14]. Algoritam se zasniva na procesu generisanja ljudskih ideja, poznat i kao proces brainstorminga, odakle i potiče ime.

Brainstorming proces je interpretiran i napisan kao algoritam sa nekoliko koraka. Ovi koraci pojednostavljaju proces, ali sadrže dovoljno elemenata za implementaciju algoritma optimizacije koji ima eksploraciju i eksploataciju. Svi algoritmi inteligencije

rojeva imaju jednostavne agente koji kroz generacije i inter-komunikacije poboljšavaju globalno najbolje rešenje.

Agenti u brain storm optimizacionom algoritmu su ideje. Ideje su predstavljene kao d dimenzionalni vektori. Proces brainstorminga počinje generisanjem inicijalnih ideja koje se implementiraju kao generisanje n slučajnih rešenja (d -dimenzionalni vektori). Inicijalne ideje su dalje grupisane u m klastera, obično k -sredina algoritmom (engl. k -mean algorithm). U svakom klasteru izabrana je najbolja ideja, rešenje sa najboljom vrednošću funkcije cilja, i ona je postavljena kao centar klastera. U sledećim koracima se grade nova rešenja kombinovanjem prethodno dobijenih rešenja. Postavljene su različite verovatnoće da bi se utvrdilo treba li kombinovati najbolja rešenja (centar klastera), neka slučajno izabrana rešenja ili modifikovati pojedina rešenja.

Eksploracija se takođe izvodi sa izvesnom verovatnoćom i sprovodi se zamenom centra klastera novim slučajnim rešenjem. Opisani koraci brain storm optimizacionog algoritma su predstavljeni u algoritmu 7.

Nova rešenja generišu se sledećom jednačinom:

$$x_{new} = x_{selected} + \zeta * n(\mu, \sigma) \quad (60)$$

gde x_{new} predstavlja novo rešenje u d -dimenzionalnom prostoru, $x_{selected}$ je rešenje koje je odabrano da bude potencijalno promenjeno, $n(\mu, \sigma)$ je slučajan broj generisan iz Gausove raspodele sa srednjom vrednošću μ i varijansom σ , ζ je koeficijent koji kontroliše uticaj ove slučajne promenljive. Parametar ζ se računa u svakoj generaciji po sledećoj formuli:

$$\zeta = \text{logsig}((0.5 * \text{maxIter} - \text{currentIter}) / k) * \text{rand}() \quad (61)$$

gde su maxIter i currentIter maksimalan i trenutni broj iteracija, redom. Parametar k menja nagib logaritamske sigmoid funkcije, $\text{logsig}()$. Ovaj parametar uzima slučajnu vrednost iz intervala $[0, 1]$.

Algorithm 7 Pseudo kod brain storm optimizacionog algoritma

```
1: Inicijalizacija
2: Nasumično generiši  $n$  rešenja.
3: repeat
4:   Grupiši  $n$  rešenja u  $m$  klastera.
5:   Rangiraj rešenja unutar klastera i postavi najbolje kao centar klastera.
6:   Generiši slučajan broj  $r$  između 0 i 1.
7:   if  $r < p_{5a}$  then
8:     Izaberi jedan centar klastera na slučajan način.
9:     Generiši slučajno rešenje i postavi ga umesto odabranog centra klastera.
10:  end if
11:  repeat
12:    Generiši novo rešenje.
13:    Generiši slučajan broj  $r$  između 0 i 1.
14:    if  $r < p_{6b}$  then
15:      Izaberi klaster sa verovatnoćom  $p_{6bi}$ .
16:      Generiši slučajan broj  $r_1$  između 0 i 1.
17:      if  $r_1 < p_{6bii}$  then
18:        Dodaj slučajnu vrednost na centar klastera kako bi se generisalo novo rešenje.
19:      else
20:        Izaberi slučajno rešenje iz odabranog klastera i dodaj slučajnu vrednost na njega kako bi se generisalo novo rešenje.
21:      end if
22:    else
23:      Izaberi nasumično dva klastera.
24:      Generiši slučajan broj  $r_2$  između 0 i 1
25:      if  $r_2 < p_{6c}$  then
26:        Kombinuj centre klastera kako bi se generisalo novo rešenje.
27:      else
28:        Izaberi po jedno rešenje iz svakog odabranog klastera na slučajan način i generiši novo rešenje kao njihova kombinacija.
29:      end if
30:    end if
31:    Sačuvaj generisana rešenja u prethodnim koracima ukoliko su bolja od prethodnih.
32:  until  $n$  novih rešenja je generisano.
33: until Kriterijum zaustavljanja je zadovoljen.
```

Kao što se može uočiti u pseudo kodu navedenog u algoritmu 7, potrebno je definisati nekoliko parametara. Parametri p_{5a} , p_{6b} , p_{6bi} , p_{6bii} i p_{6c} određuju kako će biti generisano novo rešenje. Parametar p_{5a} kontroliše frekvenciju promene centra klastera novim slučajnim rešenjem, odnosno eksploraciju, p_{6b} se odnosi na verovatnoću da se novo rešenje generiše na osnovu jednog ili dva prethodna rešenja, p_{6bi} je verovatnoća izbora klastera odakle se bira rešenje koja će se koristiti za generisanje

novog rešenja i računa se kao broj rešenja u klasteru podeljen ukupnim brojem rešenja odnosno veličinom populacije. Parametar p_{6bi} se odnosi na verovatnoću izbor centra klastera ili slučajnog rešenja iz klastera. Na kraju, verovatnoća p_{6c} se koristi da bi se utvrdilo da li se kombinuju dva centra klastera ili dve slučajne ideje iz dva klastera.

8 Prilagođavanje algoritama inteligencije rojeva problemima analize i obrade medicinskih digitalnih slika

Medicinske slike različitih delova tela sadrže neke karakteristike koje su jedinstvene samo za taj deo tela. Takođe, medicinske slike se dobijaju iz različitih izvora koristeći različitu opremu i tehnologije i svaka od njih proizvodi slike sa različitim karakteristikama. Prema tome, nemoguće je imati jedan algoritam za bilo koju vrstu obrade slike koji bi dobro funkcionisao sa svim ovim slikama. Moguće je imati algoritam koji je opštiji i može se koristiti za različite delove tela ili za različite slike odnosno neku vrstu metaheuristike.

8.1 Registracija slika retine

Registracija slika ima značajne primene u medicini. Odnosi se na problem pronalaženja spacijalnog odnosa dve ili više slika, koje se obično nazivaju referentna slika i slika koja se poravnava (engl. floating image). Cilj registracije slika je da se usaglase slike koje su dobijene ili u različitim trenutcima vremena sa istog izvora, što se naziva unimodalna registracija, ili slike dobijene sa različitih izvora (npr. MRI i PET skener slike), što se naziva multimodalna registracija. Prostorna relacija između slika se može opisati linearnim transformacijama, takođe poznatim kao rigidne transformacije, ili nelinearnim (nerigidnim, elastičnim) transformacijama. Jedna metoda za rešavanje registracije slika retine rigidnim transformacijama je opisan i objavljen u [87].

Tehnike registracije slika mogu se podeliti u dve glavne grupe: tehnike zasnovane na karakteristikama (engl. feature based techniques) i tehnike zasnovane na analizi oblasti slike (engl. area based techniques) [69]. Tehnike zasnovane na karakteristikama obezbeđuju transformaciju koja mapira pomerajuću sliku u referentnu sliku na osnovu nekih zajedničkih osobina. U [13] predložen je deskriptor lokalnih karakteristika slika nazvan delimični invarijantni deskriptor karakteristika zasnovan na intezitetu (engl. partial intensity invariant feature descriptor), koji se koristi za automatsku registraciju snimaka mrežnjače odnosno retine. U [32] je predložena

metoda za automatsku registraciju slika poređenjem rezultata segmentacija baziranim na histogramu, dok su geometrijske karakteristike korištene u [30]. Metoda bazirana na algoritmima podudaranja blokova je predložena u [18]. Glavni problem koji ograničava tehnike zasnovane na karakteristikama je pronalaženje pouzdane korespondencije između slika [47].

Tehnike bazirane na analizi oblasti traže optimalne parametre transformacije jedne slike kako bi se uskladila sa referentnom slikom. Ove tehnike, za razliku od onih zasnovanih na karakteristikama, rade nad vrednostima piksela. Prednost tehnika baziranih na analizi oblasti je u tome što im nije potrebna interakcija sa korisnikom kako bi se identifikovale orijentire, niti su potrebni algoritmi segmentacije. S druge strane, one su sporije ali se mogu poboljšati identifikovanjem regiona od interesa pošto se pikseli izvan ovih regiona mogu zanemariti. U [50] predstavljen je opšti metod za procenu pouzdanosti algoritama za registraciju slika zasnovanih na analizi oblasti koji koristi *bootstrap resampling*. U [9] uveden je automatski način registracije slika, gde je u okviru preklapajućih regiona slika postavljena topološki pravilna mreža vezanih tačaka.

Sličnost dve slike zasnovanih na intenzitetu za tehnike bazirane na analizi oblasti može se definisati na brojne načine. Neka od najčešće korišćenih metrika sličnosti su suma kvadrata razlika intenziteta, unakrsna korelacija, međusobna informacija, itd. Glavni zadatak u tehnikama baziranim na analizi oblasti slike je optimizacija mera sličnosti. Ovaj problem predstavlja težak problem optimizacije.

Matematički model za registraciju slika može biti definisan na sledeći način. Algoritmi za registraciju slika počinju sa dve slike, od kojih je jedna označena kao referentna slika, a druga slika je ona koju bi trebalo poravnati odnosno slika za koju je potrebno pronaći transformaciju koja je poravnava sa referentnom slikom. Zatim je potrebno izabrati funkciju koja određuje sličnost između dve slike. Poslednji korak je optimizacija transformacije sve dok ne budu zadovoljeni kriterijumi zaustavljanja. Kriterijumi za zaustavljanje mogu biti broj iteracija za algoritam optimizacije ili željena sličnost između slika.

Registracija slika se odnosi na mapiranje koje predstavlja najbolje podudaranje između dve ili više slika iste scene snimljene u različito vreme ili snimljene različitim senzorima. Pod pretpostavkom da je slika B ona koju treba poravnati sa referentnom

slikom A, matematičko mapiranje se može definisati kao:

$$A(x, y) = \xi(B(T_\alpha(x, y))) \quad (62)$$

gde je ξ funkcija kalibracije intenziteta dok je T_α funkcija transformacije koja mapira prostorne koordinate x i y u nove prostorne koordinate x' i y' sa parametrima transformacije α :

$$(x', y') = T_\alpha(x, y) \quad (63)$$

Zadatak registracije slika je određivanje prostorne transformacije koja maksimizuje sličnost između referentne slike i slika koje se poravnavaju. Prethodni opis registracije slika se može predstaviti sledećom jednačinom:

$$T^* = \arg \max O(A, T_\alpha(B)) \quad (64)$$

gde je $T_\alpha(B)$ jedna moguća transformacija i O predstavlja funkciju cilja koja je zapravo mera sličnosti. U ovom slučaju predstavlja transformaciju sa parametrima α koja maksimizuje vrednost objektne funkcije nad svim mogućim transformacijama. Za različite svrhe koriste se različite transformacije. Jedan tip transformacija T su linearne transformacije koje uključuju translaciju, rotaciju, skaliranje i druge afine transformacije, koje se zajedno nazivaju i rigidne transformacije. S druge strane, postoje nelinearne transformacije, koje se nazivaju i elastične ili ne-rigidne transformacije, koje uključuju radijalne bazne funkcije, modele fizičkog kontinuuma i velike modele deformacija. Elastične transformacije mapiraju krive u druge krive. U ovom radu korišćene su rigidne transformacije koje uključuju translaciju i rotaciju. Ove transformacije su definisane sa dva parametra translacije t_x i t_y i uglom rotacije θ . Formula ove transformacije može se napisati u obliku matrice:

$$T = \begin{vmatrix} \cos(\theta) & -\sin(\theta) & t_x \\ \sin(\theta) & \cos(\theta) & t_y \\ 0 & 0 & 1 \end{vmatrix} \quad (65)$$

Pronalaženje optimalne transformacije zavisi od izabrane mere sličnosti. U slučaju tehnika zasnovanih na karakteristikama, mera sličnosti predstavlja indikator

bliskosti između dve slike baziran na vrednostima karakteristika dok u slučaju tehnika zasnovanih na analizi oblasti je baziran na vrednostima intenziteta. Jedna od najjednostavnijih mera sličnosti je srednja kvadratna razlika između vrednosti intenziteta. Još neke mere sličnosti su unakrsna korelacija i normalizovana unakrsna korelacija [95]. Jedna od najčešće korišćenih mera sličnosti je uzajamna informacija koja je definisana sledećim izrazom [43]:

$$I(A, B) = H(A) + H(B) - H(A, B) \quad (66)$$

gde A i B predstavljaju referentnu sliku i sliku koja se poravnava sa njom, $H(A)$ i $H(B)$ su entropije slika i $H(A, B)$ je zajednička entropija. Entropija slike se može izračunati pomoću sledeće jednačine:

$$H(A) = -\frac{1}{N} \sum_{i=1}^N p_i \log p_i \quad (67)$$

gde je N broj piksela na slici i p_i je normalizovani broj piksela sa nivoom intenziteta i . Takođe, normalizovana uzajamna informacija se često uzima za meru sličnosti. Definiše se kao:

$$I(A, B) = \frac{H(A) + H(B)}{H(A, B)} \quad (68)$$

Procena merenja sličnosti može biti računski veoma skupa. Da bi se smanjilo vreme računanja, jedan od često korišćenih pristupa je da se prvo izvrši registracija nad slikama sa smanjenom rezolucijom. Rezultujuća transformacija se zatim koristi kao početna tačka za sledeću rundu registracije koja se izvodi nad slikama veće rezolucije [61]. Uključivanje tehnike multirezolucije u registraciju slika ima dve prednosti: povećava performanse i poboljšava stabilnost optimizacije zato što smanjuje razliku između lokalnih minimuma i njihovih okolina.

Najjednostavnija verzija multirezolucije je rezolucija na dva nivoa, gde je izvršeno samo jedno smanjenje rezolucije. U ovom radu koristili smo slike sa rezolucijom koja nije bila jako visoka, tako da nije bilo potrebe za više od jednog smanjenja rezolucije. Smanjenje rezolucije može se izvršiti jednostavnim uprosečavanjem. Regioni veličine $n \times n$ postaju jedan piksel čiji je nivo intenziteta podešen na prosečnu vrednost odgovarajućih $n * n$ piksela. Odgovarajuća veličina regiona je određena empirijski.

U ovom istraživanju smo koristili sliku sa smanjenom rezolucijom da bi pronašli početni opseg prostora za pretragu. Prvi korak algoritma je traženje parametara transformacije u širokom intervalu mogućih vrednosti pomoću slike sa smanjenom rezolucijom. Rezultati ovog pretraživanja koriste se za smanjivanje prostora pretrage slike pune rezolucije, gde se vrši fino pretraživanje oko vrednosti dobijenih u prethodnom koraku. Razmatrali smo linearne transformacije, translaciju i rotaciju, prema jednačini 65. Za meru sličnosti korišćena je normalizovana uzajamna informacija definisana jednačinom 68. Funkcija cilja za registraciju slike koja koristi uzajamnu informaciju kao meru sličnosti ima brojne lokalne maksimume pa je potrebna globalna optimizacija za pretraživanje prostora rešenja [111].

Normalizovana uzajamna informacija za dve slike ne može da pređe vrednost koja se dobija kada su dve slike jednake. Međutim, kada se slika translira samo za jedan piksel ili rotira za samo 1° , normalizovana uzajamna informacija se značajno menja. Na primer, za jednu test sliku maksimalna normalizovana uzajamna informacija bila je 1.000 (u situaciji kada se koriste iste slike). Ukoliko se slika translira duž x-ose za samo 1 piksel, normalizovana uzajamna informacija pada na vrednost 0.681. Dalje promene su manje u odnosu na ovu i sve su manje kako se translacija povećava. Na primer, normalizovana uzajamna informacija za translaciju duž x-ose za 10 piksela bila je 0.607 a za translaciju za 20 piksela bila je 0.590. Slična situacija je i za rotaciju, normalizovana uzajamna informacija od maksimalne vrednosti 1.000 pala je na 0.648 za rotaciju od 1° . Ovakva objektna funkcija je veoma teška jer je globalni optimum skriven u vrlo uskom prostoru, dok je ostatak prostora za pretraživanje relativno ravan sa brojnim lokalnim optimumima. Algoritam za pretragu ima vrlo malo mogućnosti da iskoristi eksploataciju ukoliko nema barem jedan pogodak u uskom području oko globalnog optimuma.

Na osnovu ovih zapažanja, prilagođen je algoritam vatrometa. U početku je potrebna široka pretraga kako bi se pokrio ceo prostor pretrage sa ciljem da se nađe onaj uski prostor u kojem je globalni maksimum. Broj rešenja kandidata (varnica) treba da bude mnogo veći nego za većinu aplikacija kako bi se ubrzao početni pogodak blizu globalnog optimuma. Međutim, koeficijent amplitude bi trebao biti mali jer izvan uskog područja globalnog optimuma ne pomaže da se eksploatacija radi bliže ili šire. Kada se taj uski prostor pronađe, eksploatacija bi trebalo da bude veoma


dobra sa malim koracima. Da bi se obezbedili fini koraci u kasnijim iteracijama, smanjujemo opseg amplitude eksplozije u zavisnosti od broja evaluacija (iteracija). U početku, opseg pretrage treba da bude širi, ali nakon malog broja evaluacija bi trebalo da postane mnogo manji. U našoj predloženoj metodi ovo je postignuto kvadratnim smanjenjem opsega sa napredovanjem evaluacija. Empirijski smo ustanovili da bi nakon 20% evaluacija opseg trebalo da se smanji na 0.5, a nakon 90% procena treba da se smanji na 0.1. To je rezultiralo sledećom adaptacijom amplitude eksplozije:

$$\Delta X_k = A_i \times rand(-s(t), s(t))$$

$$s(t) = 2.14\left(\frac{t}{tMax}\right)^2 - 2.93\left(\frac{t}{tMax}\right) + 1 \quad (69)$$

gde je t broj trenutne a $tMax$ maksimalni broj evaluacija.

Raspon pretraživanja za parametre transformacije mora biti dovoljno širok da pokrije sve moguće situacije. U ovom istraživanju smo pretpostavili da je interval pretraživanja za t_x i t_y $[-100, 100]$, dok je za θ $[-50, 50]$. Za ovaj opseg pretraživanja, predloženi algoritam vatrometa nije bio u mogućnosti da pronađe optimalno rešenje kada se koristi slika u punoj rezoluciji. U tabeli 1 dati su rezultati za registraciju slika prikazanih na slici 30. Originalna slika je translirana za $t_x = 60$, $t_y = 70$ i rotirana za $\theta = 30^\circ$ (podrazumeva se da je koordinatni početak u gornjem levom uglu).



Slika 30: Registracija slika retine: parametri transformacije $t_x = 60$, $t_y = 70$, $\theta = 30^\circ$

Algoritam je pokrenut 30 puta za svaki eksperiment sa različitim inicijalizacijama. Srednja vrednost, standardna devijacija, kao i minimalni i maksimalni rezultati

navedeni su u tabeli 1. Takođe su prikazana i prosečna vremena izvršenja. Iz tabele 1 se može videti da povećanje broja evaluacija ne pomaže, pronađena rešenja su daleko od realnih vrednosti parametara transformacije. Vremena računanja su značajna, jer funkcija cilja obrađuje celu sliku i zahteva oko 500 puta više vremena od standardnih benčmark funkcija.

Tabela 1: Procenjene vrednosti t_x , t_y i θ sa različitim brojem iteracija i slikama u punoj rezoluciji, $t_x = 60$, $t_y = 70$, $\theta = 30^\circ$, $t_x, t_y \in [-100, 100]$, $\theta \in [-50, 50]$

Evals		t_x	t_y	θ
1000 159s	Avg.	61.849	49.389	21.649
	Std.	25.127	52.668	15.984
	Min.	4.639	-55.278	-12.004
	Max.	87.281	95.279	34.915
2000 312s	Avg.	49.487	68.447	29.576
	Std.	18.847	4.522	1.573
	Min.	25.870	60.601	27.557
	Max.	69.764	72.286	31.230
3000 473s	Avg.	51.055	59.352	19.899
	Std.	24.449	19.953	19.836
	Min.	7.716	24.133	-15.361
	Max.	67.577	70.081	30.002

Tabela 2: Procenjene vrednosti t_x , t_y i θ sa različitim brojem iteracija i slikama u punoj rezoluciji, $t_x = 60$, $t_y = 70$, $\theta = 30^\circ$, $t_x, t_y \in [t_{x,y} - 2, t_{x,y} + 2]$, $\theta \in [\theta - 2, \theta + 2]$

Evals		t_x	t_y	θ
500 76s	Avg.	60.497	70.261	29.610
	Std.	0.542	0.309	0.878
	Min.	59.876	69.907	28.040
	Max.	61.113	70.719	30.018
750 121s	Avg.	60.031	69.976	29.998
	Std.	0.029	0.063	0.003
	Min.	60.005	69.870	29.993
	Max.	60.075	70.024	30.000
1000 159s	Avg.	59.992	70.020	30.004
	Std.	0.043	0.023	0.003
	Min.	59.924	69.995	30.000
	Max.	60.028	70.046	30.009

S druge strane, ako je interval pretraživanja uzak, predloženi prilagođeni FWA pronalazi dobra rešenja u malom broju procena, kao što se može videti u tabeli

2. Ako se prostor pretraživanja suzio, u samo 500 procena pronađeni su parametri transformacije prihvatljive tačnosti. Vreme izvršenja bilo je 76s. Tačnost između 750 iteracija i 1000 iteracija je skoro ista. Da bi se suzio prostor za pretragu parametara, koristi se jedno smanjenje rezolucije.

Svrha smanjenja rezolucije je pronalaženje približnog rešenja i njegovo korišćenje za sužavanje prostora pretrage slike pune rezolucije. Kada se rezolucija smanji, pretraga je brža, ali i manje precizna jer se broj originalnih piksela spaja u jedan. Ova operacija ima efekat filtera za omekšavanje gde su ivice prigušene. Sa omekšanim ivicama moguće je koristiti jednostavniju fitnes funkciju kao što je zbir apsolutnih razlika:

$$f(A, B) = \sum_{i=1}^n \sum_{j=1}^m |A(i, j) - B(i, j)|, \quad (70)$$

gde su A i B referentna slika i slika koja se poravnava sa njom velicine $n \times m$. Ovakve mere sličnosti su neupotrebljive kada postoji mnogo ivica na slikama, jer neusklađenost za samo jedan piksel na rubovima stvara ogromne razlike. Mogućnost da se koristi ova jednostavnija funkcija cilja sa smanjenim rezolucijama je važna, jer omogućava značajno smanjenje vremena računanja. Razlog tome je što kada se koristi normalizovana uzajamna informacija definisana jednačinom (68) kao objektna funkcija, vreme izvršenja nije značajno smanjeno kada se rezolucija slike smanji. Izračunavanje te ciljne funkcije uključuje samo jedan prolaz kroz sliku za izgradnju histograma. Ta operacija zavisi od rezolucije, ali uključuje samo jednu jednostavnu operaciju inkrementacije. Nakon toga se koristi histogram koji uključuje složenije operacije i veličina je fiksirana na 256 za jednu sliku i do 256×256 za zajedničku entropiju, bez obzira na rezoluciju. Navedena razlika je značajna za vreme izvršenja algoritma.

U korišćenom algoritmu je predloženo još jedno podešavanje za slike sa smanjenom rezolucijom. Pošto su parametri dobijeni sa smanjenim slikama neprecizni, fina eksploatacija nije potrebna, a sa druge strane je potrebno više eksploracije zbog širokog prostora pretrage. Na osnovu ovoga, umesto da se koristi korigovana jednačina (69) od početka algoritma, u prvih 1000 evaluacija korišćen je originalni FWA.

U tabeli 3 prikazani su eksperimentalni rezultati za različita smanjenja rezolucije. U slučaju smanjenja rezolucije $k \times k$, parametri transformacije su takođe smanjeni

faktorom k , a kasnije su ponovo vraćeni kako bi se izvršilo poređenje. Vreme računanja je značajno smanjeno korišćenjem smanjene rezolucije i jednostavnije funkcije cilja: 12 puta za smanjenje 4×4 . Štaviše, sa slikom u smanjenoj rezoluciji pronađeni su optimalni parametri sa prihvatljivom tačnošću. U tabeli 1 je pokazano da u punoj rezoluciji algoritam nije bio u stanju da pronađe rešenje. Iz tabele 3 se vidi da smanjenje 2×2 takođe nije dovoljno, ali smanjenje 4×4 daje dobre rezultate. Dalje smanjenje rezolucije čini rezultate manje preciznim, a standardna devijacija je veća jer je previše piksela spojeno u jedan.

Na osnovu rezultata iz tabele 2 i tabele 3 može se zaključiti da je najbolja kombinacija da se koristi smanjenje 4×4 u prvom koraku sa 3000 evaluacija. Ovo će naći rešenje tako da greška i 3σ kombinovano budu manji od 2. U drugom koraku opseg pretraživanja za parametre transformacije može se svesti na parametre dobijene u prvom koraku.

Tabela 3: Procenjene vrednosti t_x , t_y i θ u različitim rezolucijama, $t_x = 60$, $t_y = 70$, $\theta = 30^\circ$, $t_x, t_y \in [-100, 100]$, $\theta \in [-50, 50]$

Red./vreme		t_x	t_y	θ
2x2 81s	Avg.	59.852	66.139	29.750
	Std.	0.547	8.639	0.353
	Min.	59.309	50.703	29.413
	Max.	60.732	70.308	30.117
4x4 40s	Avg.	60.167	69.785	29.772
	Std.	0.491	0.247	0.113
	Min.	59.725	69.423	29.607
	Max.	60.870	69.969	29.845
6x6 30s	Avg.	59.445	73.322	30.623
	Std.	0.263	3.003	1.561
	Min.	59.220	71.009	29.656
	Max.	59.876	77.460	33.381
8x8 28s	Avg.	58.337	71.122	30.857
	Std.	1.107	2.637	1.647
	Min.	57.433	68.173	29.810
	Max.	59.770	72.653	32.090
10x10 28s	Avg.	58.780	68.452	29.060
	Std.	0.278	3.715	1.381
	Min.	58.407	61.868	28.407
	Max.	59.067	70.871	30.329

Parametri za algoritam vatrometa postavljeni su empirijski. Broj vatrometa je

postavljen na 5. Amplituda eksplozije je postavljena na 40, a minimalni i maksimalni broj varnica je podešen na 2, odnosno 40.

Parametri optimizacije su parametri translacije t_x i t_y i ugao rotacije θ , gde su sva tri parametri realni brojevi. Ovaj model s realnim brojevima pokriva slike stvarnog sveta gde je neusklađenost neprekidna i čini naše rezultate uporedivim sa rezultatima iz [109].


Uključili smo nekoliko koraka prerade. Slike su pravougaonog oblika i kada se izvrši rotacija, neke informacije sa slike bi bile izgubljene. Pošto je potrebno imati sve informacije, na početku smo proširili sliku dodavanjem crnog okvira dovoljno velikog da sačuva sve originalne piksele nakon rotacije. Okvir slike je postavljena tako da bude iste boje kao i pozadina. Za slike bez pozadine (slika 32 i slika 33) koristili smo unutrašnji deo slike koji je zajednički na obe slike što predstavlja čestu praksu.

Za rotaciju, svaki kvadratni piksel može u novoj poziciji delimično pokriti do šest piksela u originalnoj mreži (četiri za realne translacije) pa smo pripisali vrednost intenziteta originalnog piksela svim pogođenim pikselima, sa odgovarajućim težinama. Takva transformacija nije sasvim reverzibilna.

Parametri za algoritam vatrometa su određeni empirijski, koristeći teorijske smernice objašnjene ranije. Naš predloženi algoritam je testiran na DRIVE skupu slika opisanom u [75] javno dostupnom na www.isi.uu.nl/Research/Databases/DRIVE/. Ova baza podataka sadrži 40 slika retine. Originalne slike su u RGB modelu boja. U [47] korišćena je samo zelena komponenta jer je imala najveći kontrast između vena i pozadine. Takođe je moguće transformisati sliku u crno-belu. Testirali smo i slike zelenih kanala i sive slike, i takođe došli do zaključka da je slika zelenog kanala nešto bolja za registraciju pošto su vene izraženije pa im je funkcija cilja bolje određena. Da bismo testirali naš algoritam, svaku sliku smo transformisali poznatim parametrima transformacije i uporedili ih sa parametrima pronađenim algoritmom vatrometa.

U [109] je predložen bakterijska hemotaksija višestrukih kolonija (engl. bacterial multiple colony chemotaxis, BMCC) kao optimizacioni algoritam, tri-linearna interpolacija i parcijalna distribucija zapremine za eliminaciju lokalnih ekstrema. Prikazani su rezultati za slike retine transformisane istim parametrima za tri različite mere

sličnosti, koeficijent korelacije entropije (engl. entropy coleration coefficient, ECC), prosečna ECC dobijen iz tri-linearne interpolacije i parcijalne raspodele volumena i njihova nova kombinacija. Parametri transformacije prvog test para su $t_x = 5$, $t_y = 10$ i rotacija za $\theta = 20^\circ$ (slika 31). Najbolju registraciju su postigli korišćenjem predložene kombinacije kao funkcija cilja. U [109] su prijavili $t_x = 4.920$, $t_y = 9.988$ i $\theta = 20.002^\circ$. Testirali smo naš predloženi algoritam za iste parametre i dobili bolje rezultate. Za parametre translacije su dobijeni $t_x = 5.069$, $t_y = 9.984$, $\theta = 20.000^\circ$.



Slika 31: *Registracija slika retine: Test par 1, $t_x = 5$, $t_y = 10$, $\theta = 20^\circ$*


U drugom primeru iz rada [109] korišćeni su parametri transformacije $t_x = 3$, $t_y = 3$ i $\theta = 15^\circ$ (slika 32). Najbolja aproksimacija dobijena je korišćenjem njihove predložene metode i prijavljeni su sledeći parametri transformacije: $t_x = 2.883$, $t_y = 3.010$ i $\theta = 15.002^\circ$.

Rezultati iz [109] su upoređeni sa tri druga algritma za optimizaciju: optimizacija rojem haotičnih čestica (engl. chaotic particle swarm optimisation, CPS), elitni genetski algoritam (engl. elite preservation genetic algorithm, EGA) i algoritam kolonije mrava (engl. ant colony algorithm, ACA) i oni su pronašli da njihov predloženi algoritam pronalazi bolje parametre transformacije. Naš predloženi algoritam je pronašao parametre transformacije najbliže pravim vrednostima: $t_x = 2.986$, $t_y = 2.999$ i $\theta = 15.008^\circ$. Može se primetiti da je naš predloženi metod pronašao nešto bolje rezultate od najboljih rezultata iz [109] pa je time i indirektno bolji od algoritama korišćenih za poređenje u [109]. Ovo poređenje je prikazano u tabeli 4. Pored toga, rezultati u [109] su dobijeni korišćenjem višestruke redukcije rezolucije, dok naši rezultati su dobijeni sa samo jednim smanjenjem rezolucije.

Za poslednji primer parametri transformacije su postavljeni na $t_x = -5$, $t_y = 5$ i


Tabela 4: Poređenje rezultata dobijenih predloženim algoritmom vatrometa i metodom iz literature [109]

Eval.	t_x	t_y	θ
Tačni parametri	3	3	15
EGA	2.893	3.092	15.180
ACA	2.891	3.113	15.176
CPSO	2.819	3.016	15.226
BMCC	2.883	3.010	15.002
FWA	2.986	2.999	15.008



Slika 32: Registracija slika retine: Test par 2, $t_x = 3$, $t_y = 3$, $\theta = 15^\circ$

$\theta = 9^\circ$ (slika 33). U [109] prijavljeni su sledeći rezultati: $t_x = -5.1744$, $t_y = 4.7834$ i $\theta = 9.0011^\circ$, dok je naš predloženi algoritam pronašao optimalne parametre za vrednosti $t_x = -5.0020$, $t_y = 4.9967$ i $\theta = 8.9826^\circ$ što je opet bolje.



Slika 33: Registracija slika retine: Test par 3, $t_x = 5$, $t_y = 5$, $\theta = 9^\circ$

U tabeli 5 upoređeni su rezultati našeg predloženog algoritma i rezultati iz [109] za prikazane primere. U [66] predložen je algoritam za registraciju slika retine pomoću maksimizacije očekivanja zajedno sa uzajamnom informacijom. Metoda je tražila

parametre transformacije nad skupom celih brojeva, tako da su parametri koji su korišćeni u ovom istraživanju dobijeni bez greške tom metodom. Za rotaciju za 20° najveća greška je bila 1.425, dok je prosečna greška bila 0.204. Sa našim predloženim algoritmom greška za ugao u svim slučajevima bila je manja od 0.134 što znači da je naš predloženi algoritam nadmašio i metod predložen u [66]. Vreme rada za naš algoritam je bilo 40s za korak 1 (iz tabele 3) i 159s za korak 2 (iz tabele 2), dok radovi [109] i [66] nisu objavili vreme izvršenja predloženih metoda.

Tabela 5: *Poređenje rezultata dobijenih predloženim algoritmom vatrometa i metodom iz literature [109]*

Test par		REAL	BMCC	FWA step1	FWA step2
1	t_x	5	4.920	4.860	5.069
	t_y	10	9.988	9.681	9.984
	θ	20	20.002	20.027	20.000
2	t_x	3	2.883	4.001	2.986
	t_y	3	3.010	3.622	2.999
	θ	15	15.002	15.567	15.008
3	t_x	-5	-5.175	-4.279	-5.002
	t_y	5	4.783	5.188	4.997
	θ	9	9.001	10.472	8.983

Veće vrednosti parametara možda neće imati fizički smisao s obzirom na karakteristike opreme za generisanje slike i na ograničenja položaja i kretanja pacijenata, ali smo testirali registraciju za parametre $t_x = 50$, $t_y = 80$ i $\theta = 60^\circ$ da bismo dokazali kvalitet našeg predloženog algoritma. Za ovaj primer, naš predloženi algoritam uspešno je pronašao $t_x = 50.0036$, $t_y = 79.9661$ i $\theta = 60.0001^\circ$ sa istim vremenom izvršenja kao i predhodnim primerima.

Testirali smo naš algoritam sa istim slikama i različitim parametrima transformacije, kao i sa različitim slikama iz navedenog skupa podataka [75] i postigli gotovo savršenu registraciju u svim slučajevima, što dovodi do zaključka da je predloženi algoritam vatrometa potpuno prikladan za registraciju slika retine.

8.2 Segmentacija MRI slika mozga

Segmentacija MRI mozga je intezivno istraživana tema jer je od izuzetne važnosti za praćenje napretka ili remisije brojnih bolesti kao što su Alchajmerova bolest [15],

epilepsija [40], skleroza [72], šizofrenija [45], itd. Na MRI slikama mozga gotovo uvek je potrebno razlikovati tri glavne komponente: siva materija, bela materija i cerebralna spinalna tečnost. Za izdvajanje ove tri komponente potrebno je koristiti 3 trešhold vrednosti, pošto je potrebno razlikovati i pozadinu. Kod MRI slika, pored ove tri karakteristične materije, postoje i druge medicinski bitne strukture, na primer, različite abnormalnosti, edem, masnoća, meka tkiva, itd., tako da u zavisnosti od svojstava koje treba detektovati, može biti potrebno i više trešhold vrednosti [25].

Deterministički algoritam koji pronalazi optimalne trešhold vrednosti Kapurovom ili Otsuovom metodom je iscrpna pretraga (engl. exhaustive search). Pošto su MRI slike najčešće 8-bitne slike odnosno imaju 256 nijansi sive, za dve trešhold vrednosti je potrebno proveriti sve moguće redoslede kojih ima 256^2 , za 3 trešhold vrednosti 256^3 , itd. Eksponencijalni rast ovog algoritma čini ga neupotrebljivim za potrebe pronalaženja većeg broja trešhold vrednosti.

Pronalaženje više trešhold vrednosti za segmentaciju digitalnih slika predstavlja težak problem optimizacije. U ovom istraživanju predložen je algoritam slepog miša za optimizaciju funkcije cilja koju definišu Kapurova ili Otsuova metoda za pronalaženje optimalnih trešhold vrednosti za segmentaciju MRI slika mozga [85]. Za ulaznu sliku potrebno je odrediti najbolje trešhold vrednosti. Broj pragova koje treba pronaći predstavlja dimenziju problema. Svaka trešhold vrednost može biti bilo koji ceo broj iz intervala $[0, 255]$.

Algoritam slepog miša se mora podesiti kako bi mogao da se primeni na problem traženja trešhold vrednosti. BA je namenjen za pretragu kontinualnog prostora pretrage, dok trešhold vrednosti moraju biti celobrojne. Intenzitet piksela u digitalnim slikama zapravo predstavlja zaokružen izmeren analogni intenzitet koji je realan broj, tako da je prvobitno intenzitet realna vrednost, ali je standard da se podaci digitalne slike čuvaju kao celobrojni brojevi. Stoga je prikladno tražiti pragove u prostoru realnih brojeva, a zatim dobijeni broj zaokružiti, kao što je to učinjeno u svrhu čuvanja slike u digitalnom formatu. To znači da kada je d -dimenzionalni vektor realnih brojeva generisan od strane BA, prvi korak je da se zaokruže elementi vektora do najbližih celih brojeva. Još jedno ograničenje koje je specifično za određivanje trešhold vrednosti je da one moraju biti sortirane. Intenziteti za piksele sa vrednošću intenziteta manjim od praga t_1 biće postavljeni na nulu, pikseli sa intenzitetom

između t_1 i t_2 treba da budu postavljeni na isti intenzitet veći od nule u zavisnosti od broja pragova, itd. Vrednosti praga moraju zadovoljiti nejednakost $t_i < t_{i+1}$ za svako $i \in \{1, 2, \dots, d\}$. Da bi se osigurao ovaj uslov nakon što se vektor vrednosti pragova generiše i zaokruži, elementi vektora se i sortiraju. Na taj način je prvi element najmanji i predstavlja vrednost za t_1 , drugi je drugi najmanji i to je vrednost za t_2 dok je poslednji najveći element vektora i vrednost za t_d . Sa ovim modifikacijama, algoritam slepog miša se može primeniti na problem pronalaženja trešhold vrednosti bilo Otsuovom bilo Kapurovom metodom.

Da bismo ubrzali proces računanja funkcije cilja, predložili smo korišćenje rekurzivnih funkcija i look-up tabela. Kapurova i Otsova fitnes funkcija je računski zahtevna. Složenost izračunavanja i vremena izvršavanja se može smanjiti izbegavanjem ponovljenih izračunavanja. U obe metode kumulativne verovatnoće w definisane jednačinom 22 se mogu definisati sledećom rekurzivnom funkcijom:

$$\begin{aligned} w(i, j) &= 0, & \text{if } i \geq j, \\ w(0, t_i + 1) &= w(0, t_i) + P_{t_i}, \\ w(t_{i-1}, t_i) &= w(0, t_i) - w(0, t_{i-1}) \end{aligned} \tag{71}$$

gde su t_i trešhold vrednosti a P_{t_i} su verovatnoće pojavljivanja intenziteta nivoa t_i .

Look-up tabela w je dimenzije 256×256 , pošto su korišćene 8-bitne slike. Elementi ove tabele su $w(t_{i-1}, t_i)$ tako da svi momenti se mogu izračunati samo jednom sa složenošću $O(256^2)$. U daljem računu se svim ovim elementima pristupa u $O(1)$ vremenu.

Slično tome, look-up tabele mogu biti napravljene za kumulativne entropije h_s i σ funkcije. Kumulativne entropije h_s se koriste za Kapurovu metodu i definisane su rekurzivnom funkcijom:

$$\begin{aligned} h_s(i, j) &= 0, & \text{if } i \geq j, \\ h_s(0, t_i + 1) &= h_s(0, t_i) + P_{t_i} \ln(P_{t_i}), \\ h_s(t_{i-1}, t_i) &= h_s(0, t_i) - h_s(0, t_{i-1}) \end{aligned} \tag{72}$$

gde je t_i ponovo trešhold vrednosti, a P_{t_i} verovatnoća intenziteta t_i .

Pomoću ove dve tabele, w i h_s , entropija H za Kapurovu funkciju cilja se računa na sledeći način:

$$H(t_{i-1}, t_i) = -\frac{1}{w(t_{i-1}, t_i)} \cdot \left[h_s(t_{i-1}, t_i) - w(t_{i-1}, t_i) \cdot \ln w(t_{i-1}, t_i) \right] \quad (73)$$

Za Otsuovu metodu je potrebna pomoćna tabela δ za računanje σ funkcija i ona se može dobiti istom metodom kao i prethodne dve tabele. Rekurzivna funkcija za δ definiše se kao:

$$\begin{aligned} \delta(i, j) &= 0, \quad \text{if } i \geq j, \\ \delta(0, t_k + 1) &= \delta(0, t_k) - t_k P_{t_k}, \\ \delta(t_{k-1}, t_k) &= \delta(0, t_k) - \delta(0, t_{k-1}) \end{aligned} \quad (74)$$


Konačno, σ funkcija za Otsuovu metodu se računa sledećom formulom:

$$\sigma(t_{k-1}, t_k) = w(t_{k-1}, t_k) \left(\frac{1}{w(t_{k-1}, t_k)} \cdot \delta(t_{k-1}, t_k) - \delta(0, L) \right)^2 \quad (75)$$

Da bi testirali i pokazali kvalitet predloženog algoritma, uporedili smo ga sa metodom predloženom u [68] i metodom iz rada [57]. Kako bi obezbedili pravedno poređenje, koristili smo iste test slike: deset T2 MRI slojeva mozga prikazanih na slici 34. Sve test slike su sa internet repozitorijuma medicinskih slika [42], besplatne i dostupne za preuzimanje. Sve slike su sa 256 nivoa sive dimenzija 256×256 .

Parametri algoritma slepog miša su određeni empirijski:

- veličina populacije 40,
- $\alpha = 0.99$,
- $\gamma = 0.97$,
- interval frekvencije $[-6, 8]$,
- maksimalan broj iteracija je postavljen na 500.



Slika 34: *Test slike*

Kako se radi o stohastičkom algoritmu potrebno je ispitati stabilnost istog, pa je algoritam pokretan 100 puta za svaki test primer i prijavljeni su prosečni rezultat i standardna devijacija kao i u [68].

Tabela 6: *Trešhold vrednosti i vrednosti funkcije cilja dobijene iscrpnom pretragom za Kapurovu metodu*

Slike	K	Trešhold vrednosti	Funkcija cilja
Slice 22	2	95, 183	9.2155
	3	57, 115, 185	11.7333
	4	43,87,131,185	13.9555
	5	44, 86, 127, 174, 208	16.1228
Slice 32	2	109, 185	9.2645
	3	53, 115, 185	11.6835
	4	39, 84, 131, 189	13.9406
	5	35, 78, 123, 174, 207	16.0504
Slice 42	2	113, 183	9.2585
	3	83, 131, 187	11.5779
	4	29, 76, 127, 187	13.8650
	5	25, 68, 114, 156, 194	16.0325
Slice 52	2	117, 185	9.2447
	3	109, 165, 203	11.5795
	4	91, 131, 173, 209	13.7502
	5	23, 67, 117, 167, 203	15.8839
Slice 62	2	121, 187	9.3367
	3	101, 147, 195	11.6745
	4	93, 133, 175, 211	13.7812
	5	19, 65, 113, 158, 199	15.9035
Slice 72	2	117, 179	9.4205
	3	99, 141, 187	11.6935
	4	99, 139, 179, 214	13.8463
	5	14, 65, 119, 171, 211	15.8566
Slice 82	2	111, 169	9.1910
	3	103, 145, 189	11.4269
	4	97, 133, 169, 210	13.5191
	5	10, 62, 107, 148, 190	15.6409
Slice 92	2	109, 173	8.7906
	3	105, 157, 205	11.1640
	4	97, 135, 173, 211	13.2974
	5	5, 61, 109, 159, 205	15.4667
Slice 102	2	107, 173	8.5283
	3	93, 141, 189	10.9277
	4	1, 64, 119, 173	13.1326
	5	102, 115, 152, 169, 214	15.4124
Slice 112	2	105, 163	8.1476
	3	1, 70, 141	10.6029
	4	1, 66, 123, 171	13.0591
	5	58, 95, 133, 172, 210	15.2847

Cilj predložene modifikacije algoritma slepog miša je da se dobiju optimalne trešhold vrednosti Kapurovom i Otsuovom metodom. MRI slike su segmentirane sa različitim brojem trešhold vrednosti (različiti nivoi segmentacije): broj trešholda je $m = 2, 3, 4, 5$. Optimalne granične vrednosti dobijene iscrpnom pretragom za Kapurovu metodu prikazane su u tabeli 6, dok su za Otsuovu metodu optimalne trešhold vrednosti prikazane u tabeli 9.

Vreme izvršavanja za iscrpno pretraživanje značajno je smanjeno korišćenjem predloženih look-up tabela. Vreme izvršavanja za 3-nivo segmentaciju (dve trešhold vrednosti) bilo je 2.7 sekundi bez look-up tabela, dok je sa njima bilo samo 0.5 sekundi što je više nego 5 puta kraće. Za 4-nivo segmentaciju sa standardnom iscrpnom pretragom vreme izvršenja je bilo 280 sekundi a uvođenjem tabela smanjeno je na samo 48 sekundi, opet skoro 6 puta brže. Za segmentaciju sa 5 nivoa bilo je potrebno 18.900 sekundi za iscrpnu pretragu bez look-up tabela a sa njima je vreme izvršenja smanjeno na 3.000s. Za segmentaciju sa 6 nivoa, vremena izvršenja bi bilo nerazumno, oko jedne nedelje, i 5 godina za segmentaciju sa 7 nivoa.

Vreme izvođenja za predloženi metod je bilo 1.8 sekundi u svim slučajevima što jasno pokazuje njegovu upotrebljivost i kvalitet.

Performanse predloženog algoritma upoređen je sa rezultatima [68] i [57]. U [68] korišćen je adaptivni algoritam bakterijskog hranjenja (engl. adaptive bacterial foraging, ABF) za segmentaciju MRI slika mozga dok je u [57] predložen genetski algoritam sa realnim kodiranjem (engl. real coded genetic algorithm, RGA) za rešavanje istog problema. Predloženi ABF algoritam u [68] koristio je promenljivu veličinu pomeraja kako bi se poboljšala eksploraciona i eksploataciona sposobnost originalnog BF algoritma i testiran je za pronalaženje optimalnih trešhold vrednosti po Kapurovoj i Otsuovoj metodi. Autori rada [68] porede svoje rezultate sa drugim algoritmima optimizacije. Predloženi algoritam u [68] je pokazao bolje performanse u odnosu na PSO ili genetski algoritam (GA). Rezultati u [57] su upoređeni sa rezultatima iz [68]. Genetski algoritam sa realnim kodiranjem predložen u [57] je unapredio rezultate dobijene u [68] u slučaju korišćenja Kapurove metod. Otsuov metod nije korišćen u [57]. Zbog različitih platformi koje su korišćene u [68] i u ovom radu, vremena izvršavanja nisu poređena.

Tabela 7 pokazuje rezultate za Kapurovu funkcije cilja. Rezultati predložene

Tabela 7: *Poređenje prosečne vrednosti funkcija cilja i standardne devijacije Kapurove metode dobijenih predloženih algoritom slepog miša sa rezultatima iz [68] i [57]*

Slika	Th. vr.	PSO		FA		ABF		RGA		BA	
		mean	std	mean	std	mean	std	mean	std	mean	std
Slice 22	2	9.2136	0.0006	9.2112	0.0009	9.2155	0.0001	9.2155	0.0000	9.2155	0.0000
	3	11.329	0.0185	11.0644	0.0596	11.6876	0.0013	11.7333	0.0000	11.7333	0.0000
	4	13.5003	0.0493	13.0645	0.1632	13.931	0.0032	13.9555	0.0117	13.9555	0.0027
	5	15.7427	0.6701	15.0512	0.843	16.1127	0.0197	16.1228	0.0008	16.1228	0.0016
Slice 32	2	9.2617	0.016	9.2577	0.0022	9.2644	0.0001	9.2645	0.0000	9.2645	0.0000
	3	11.3367	0.0667	10.8842	0.1157	11.608	0.0024	11.6835	0.0000	11.6835	0.0000
	4	13.4948	0.1219	13.071	0.5885	13.8639	0.019	13.9406	0.001	13.9406	0.0008
	5	15.6579	0.983	15.2614	1.2286	15.9108	0.0341	16.0504	0.0096	16.0504	0.0028
Slice 42	2	9.2568	42	9.2525	0.016	9.2585	0.0002	9.2585	0.0000	9.2585	0.0000
	3	11.3036	0.3128	10.985	0.4249	11.5653	0.0192	11.5779	0.0000	11.5779	0.0000
	4	13.5556	0.5395	13.0969	0.7194	13.8132	0.0811	13.8650	0.0002	13.8650	0.0000
	5	15.6613	0.8736	15.0723	1.0395	15.9036	0.0937	16.0325	0.0067	16.0325	0.0041
Slice 52	2	9.2433	0.0027	9.2348	0.0042	9.2447	0.0001	9.2447	0.0000	9.2447	0.0000
	3	11.2299	0.0707	10.9217	0.1186	11.5184	0.0019	11.5795	0.0000	11.5795	0.0000
	4	13.3646	0.2358	12.9321	0.5586	13.7491	0.0119	13.7502	0.0433	13.7502	0.0106
	5	15.3383	0.4923	15.0083	0.8143	15.6564	0.166	15.8839	0.0000	15.8839	0.0001
Slice 62	2	9.3073	0.0159	9.2715	0.0659	9.3314	0.0001	9.3367	0.0000	9.3367	0.0000
	3	11.3313	0.1458	10.9987	0.2299	11.6618	0.0062	11.6745	0.0000	11.6747	0.0000
	4	13.496	0.1338	13.0549	0.4026	13.7808	0.0218	13.7812	0.0508	13.7812	0.0251
	5	15.3237	0.3248	15.0026	0.5671	15.6838	0.1074	15.9035	0.0001	15.9035	0.0021
Slice 72	2	9.4163	0.002	9.3556	0.0329	9.4205	0.0001	9.4205	0.0000	9.4205	0.0000
	3	11.4144	0.0577	11.1574	0.2359	11.6728	0.0163	11.6935	0.0000	11.6935	0.0000
	4	13.5094	0.228	13.0809	0.5655	13.8459	0.0444	13.8463	0.0566	13.8463	0.0413
	5	15.3453	0.5669	15.1595	0.8899	15.742	0.0694	15.8566	0.0161	15.8566	0.0085
Slice 82	2	9.1847	0.0236	9.1007	0.059	9.1910	0.0003	9.1910	0.0000	9.1910	0.0000
	3	11.0248	0.1057	10.6214	0.2617	11.386	0.0068	11.4269	0.0000	11.4269	0.0000
	4	13.2558	0.1475	12.664	0.436	13.5156	0.049	13.5191	0.0323	13.5191	0.0265
	5	15.0923	0.3274	14.8287	0.7075	15.3698	0.051	15.6409	0.0006	15.6409	0.0003
Slice 92	2	8.775	0.004	8.7044	0.025	8.7906	0.0002	8.7906	0.0000	8.7906	0.0000
	3	10.6335	0.2221	10.2673	0.3678	11.1514	0.0141	11.1640	0.0000	11.1640	0.0000
	4	12.9568	0.2555	12.5019	0.4718	13.282	0.0307	13.2974	0.0603	13.2974	0.0368
	5	14.7272	0.2743	14.2705	0.6143	15.1621	0.0457	15.4667	0.0010	15.4667	0.0010
Slice 102	2	8.5127	0.0008	8.5031	0.0143	8.5283	0.0001	8.5283	0.0000	8.5283	0.0000
	3	10.6913	0.1295	10.233	0.2815	10.9216	0.0036	10.9277	0.0000	10.9277	0.0000
	4	12.592	0.2107	12.237	0.3961	12.9409	0.0052	13.1326	0.0327	13.1326	0.0049
	5	14.5403	0.2319	14.0627	0.5311	14.8327	0.0102	15.4124	0.0000	15.4124	0.0000
Slice 112	2	8.1308	0.005	8.124	0.0108	8.1476	0.0022	8.1476	0.0000	8.1476	0.0000
	3	10.0312	0.0502	9.7909	0.1445	10.4429	0.0064	10.6029	0.0000	10.6029	0.0000
	4	12.3148	0.2001	12.0315	0.2446	12.6845	0.012	13.0591	0.0000	13.0591	0.0000
	5	14.2802	0.2727	13.8523	0.3782	14.5872	0.0447	15.2847	0.0015	15.2847	0.0008

metode prikazani su u poslednjoj koloni (BA), dok su u prve tri kolone prikazani rezultati metode koja je predložena u [68] zajedno sa rezultatima sa kojima je ta metoda poređena, a u četvrtoj koloni su rezultati prikazani u [57].

Kao što se može videti iz tabele 7, naš predloženi algoritam je dobio bolje rezultate, odnosno pronašao je veću entropiju, u poređenju sa metodom iz [68] u skoro svim testovima. Ako entropija nije bila veća, onda je ona bila ista kao i najbolji dobijeni

Tabela 8: *Poređenje trešhold vrednosti dobijenih korišćenjem Kapurove metode i predloženog algoritma slepog miša sa rezultatima iz [68] i [57]*

Sl	Th. no.	Dobijene trešhold vrednosti				
		PSO	GA	ABF	RGA	BA
22	2	97, 184	100, 183	95, 184	96, 184	95, 183
	3	69, 138, 207	77, 151, 175	69, 114, 185	58, 115, 185	57, 115, 185
	4	83, 116, 175, 207	94, 155, 151, 212	58, 113, 174, 208	44, 87, 131, 186	43, 87, 131, 185
	5	76, 119, 154, 184, 214	87, 101, 136, 190, 212	4, 88, 130, 176, 208	44, 86, 127, 174, 208	44, 86, 127, 174, 207
32	2	107, 185	109, 187	110, 185	109, 185	109, 185
	3	74, 157, 192	90, 120, 163	81, 134, 187	53, 116, 185	53, 115, 185
	4	95, 125, 164, 194	63, 119, 173, 208	58, 102, 142, 190	39, 84, 131, 189	39, 84, 131, 189
	5	80, 112, 139, 186, 213	79, 109, 157, 188, 201	5, 87, 128, 167, 198	34, 78, 123, 174, 207	35, 78, 123, 174, 207
42	2	111, 183	115, 184	114, 184	114, 183	113, 183
	3	80, 148, 178	67, 171, 196	74, 30, 185	84, 132, 187	83, 131, 187
	4	81, 125, 164, 197	86, 115, 166, 180	50, 100, 143, 190	30, 75, 127, 188	29, 75, 127, 187
	5	82, 115, 142, 184, 214	69, 102, 132, 175, 189	5, 97, 144, 184, 218	25, 69, 114, 156, 194	25, 68, 114, 156, 194
52	2	119, 186	118, 181	117, 186	118, 185	117, 185
	3	89, 113, 187	118, 131, 193	107, 158, 204	109, 165, 203	109, 165, 203
	4	79, 111, 141, 208	89, 110, 150, 219	90, 129, 173, 210	91, 131, 174, 209	91, 131, 173, 209
	5	6, 85, 131, 162, 203	5, 93, 114, 132, 196	5, 95, 133, 167, 203	24, 67, 118, 166, 203	23, 87, 117, 167, 203
62	2	109, 186	107, 191	119, 186	121, 187	121, 187
	3	112, 167, 187	85, 104, 183	102, 147, 199	101, 147, 196	101, 147, 195
	4	85, 134, 180, 203	97, 108, 153, 201	93, 135, 175, 212	94, 134, 175, 211	93, 133, 175, 211
	5	99, 119, 157, 181, 203	100, 116, 133, 156, 202	79, 111, 145, 179, 212	20, 65, 113, 158, 200	19, 65, 113, 158, 199
72	2	116, 177	102, 173	117, 179	117, 179	117, 179
	3	96, 178, 207	80, 122, 207	99, 150, 190	99, 141, 187	99, 141, 187
	4	96, 124, 161, 187	99, 120, 135, 172	95, 134, 174, 214	99, 140, 179, 213	99, 139, 179, 213
	5	72, 112, 151, 178, 197	81, 104, 117, 165, 207	87, 119, 150, 180, 214	14, 64, 119, 171, 211	14, 65, 119, 171, 211
82	2	110, 170	113, 159	111, 170	111, 169	111, 169
	3	103, 136, 198	82, 159, 175	111, 155, 201	103, 146, 190	103, 145, 189
	4	100, 129, 167, 188	7, 390, 160, 203	99, 135, 170, 210	98, 133, 169, 210	97, 133, 169, 210
	5	78, 105, 151, 180, 201	81, 114, 143, 164, 182	84, 133, 146, 178, 214	10, 62, 107, 148, 190	10, 62, 106, 148, 190
92	2	109, 175	101, 182	109, 174	109, 174	109, 173
	3	115, 134, 178	99, 114, 176	104, 158, 207	105, 158, 206	105, 157, 205
	4	77, 107, 149, 194	77, 119, 150, 219	102, 138, 171, 212	97, 136, 211, 173	97, 135, 173, 211
	5	90, 113, 165, 185, 206	83, 122, 151, 196, 203	96, 128, 158, 186, 216	5, 62, 109, 159, 205	5, 61, 109, 159, 205
102	2	98, 166	96, 165	108, 174	107, 174	107, 173
	3	113, 145, 180	97, 135, 151	98, 146, 189	94, 142, 190	93, 141, 189
	4	84, 124, 165, 189	107, 128, 114, 192	90, 127, 164, 198	1, 63, 120, 174	1, 63, 119, 173
	5	99, 128, 147, 194, 218	1, 62, 104, 145, 189	82, 114, 148, 184, 218	103, 115, 152, 169, 214	102, 115, 152, 169, 214
112	2	109, 162	107, 158	105, 164	106, 163	105, 163
	3	104, 163, 216	91, 179, 205	71, 123, 175	1, 70, 142	1, 70, 141
	4	63, 130, 153, 206	67, 116, 152, 187	58, 105, 146, 182	1, 65, 123, 172	1, 67, 123, 171
	5	58, 128, 155, 187, 213	57, 118, 145, 159, 209	47, 108, 142, 171, 197	1, 49, 95, 139, 183	1, 49, 95, 139, 183

rezultat iz drugih algoritama prikazanih u [68]. RGA predložen u [57] dobila je iste vrednosti objektne funkcije kao naš predloženi BA metod. Dobijene vrednosti su takođe iste kao i vrednosti izračunate iscrpnim pretraživanjem. To znači da su i RGA i BA uspešno pronašli najbolja rešenja za Kapurovu metodu. Naš predloženi algoritam imao je veću standardnu devijaciju samo u tri slučaja što znači da je predloženi BA stabilniji od RGA.

Odgovarajuće trešhold vrednosti prikazane su u tabeli 8. Može se primetiti da granične vrednosti za RGA i naše BA nisu iste, iako su odgovarajuće vrednosti fitnes funkcije iste, što je posledica zaokruživanja na 4 decimalne cifre. Na primer, Kapurova funkcija cilja za segmentaciju sa 3 nivoa za *Slice 022* sa graničnim vrednostima dobijenim od RGA (96, 184) je bila 9.215484260473097, dok je sa predloženom BA metodom i trešhold vrednostima (95, 183) bila 9.215484260475016 koja je veća. Na osnovu toga, budući da su trešhold vrednosti predložene BA metode u više slučajeva od RGA iste kao i one dobijene iscrpnom pretragom, može se zaključiti da je naš predloženi metod neznatno nadmašio RGA kao i druge metode korištene za poređenje.

Sledeći eksperiment je bio sa Otsovom metodom za pronalaženje optimalnih trešhold vrednosti. Otsuova metoda nije prikazana u [57], tako da su rezultati upoređivani samo sa rezultatima koji su prezentovani u [68], a pored toga i sa iscrpnom pretragom. Granične vrednosti zajedno sa optimalnim vrednostima funkcije cilja za Otsuovu metodu dobijene iscrpnim pretraživanjem prikazane su u tabeli 9. Rezultati iz [68] i rezultati dobijeni predloženom metodom za Otsuovu višenivoisku segmentaciju prikazani su u tabeli 10. Predloženi metod je nadmašio sve ostale metode iz [68] dobivši značajno bolje rezultate u svim slučajevima. Slično rezultatima za Kapurovu metodu, standardna devijacija je u svim slučajevima bila blizu 0, što znači da je naš predloženi algoritam uspešno pronašao optimalne trešhold vrednosti u gotovo svim testovima a da ukoliko nije pronađeno optimalno rešenje, onda je bilo blizu njega.

Tabela 9: *Trešhold vrednosti i vrednosti funkcije cilja dobijene iscrpnom pretragom za Otsuovu metodu*

Slike	K	Trešhold vrednosti	Funkcija cilja
Slice 22	2	35, 99	2273.6857
	3	23, 67, 117	2370.3354
	4	17, 51, 89, 129	2409.2509
	5	13, 41, 71, 103, 135	2429.7206
Slice 32	2	43, 113	2607.1085
	3	23, 69, 123	2712.4045
	4	19, 59, 97, 135	2751.8314
	5	17, 49, 83, 115, 149	2773.8080
Slice 42	2	45, 121	3044.4209
	3	31, 81, 135	3143.9107
	4	23, 67, 113, 161	3199.6969
	5	19, 55, 91, 129, 175	3234.6346
Slice 52	2	45, 115	2858.8493
	3	37, 89, 133	2946.9059
	4	19, 59, 97, 137	2997.4113
	5	19, 57, 93, 125, 165	3023.6302
Slice 62	2	47, 123	3369.4257
	3	39, 97, 147	3484.6113
	4	35, 85, 123, 169	3537.5265
	5	19, 59, 97, 133, 179	3578.0461
Slice 72	2	45, 127	3206.1499
	3	41, 103, 165	3342.1458
	4	37, 87, 125, 183	3405.4864
	5	21, 61, 95, 131, 185	3441.5308
Slice 82	2	45, 125	2938.1252
	3	43, 105, 171	3061.3366
	4	35, 83, 119, 181	3117.0742
	5	19, 59, 93, 127, 187	3151.6365
Slice 92	2	43, 113	2653.9932
	3	39, 95, 137	2716.0529
	4	19, 59, 99, 141	2750.6745
	5	19, 57, 89, 117, 155	2775.5399
Slice 102	2	43, 113	2571.5656
	3	39, 95, 143	2643.6091
	4	19, 59, 101, 147	2682.7476
	5	13, 55, 89, 111, 151	2703.9818
Slice 112	2	41, 111	2016.6101
	3	27, 75, 127	2090.2402
	4	23, 65, 103, 147	2126.6682
	5	17, 53, 83, 111, 153	2141.1360

Tabela 10: *Poređenje prosečne vrednosti funkcija cilja i standardne devijacije Otsuove metode dobijenih predloženih algoritom slepog miša sa rezultatima iz [68]*

Slike	Th. no.	PSO		GA		ABF		BA	
		mean	std	mean	std	mean	std	mean	std
Slice 22	2	1806.85	0.2663	1805.9258	0.3803	1808.8478	0.0021	2273.6857	0.0000
	3	2134.6878	1.9609	2119.5946	6.5105	2152.926	0.9785	2370.3354	0.0000
	4	2260.2847	3.2016	2220.8922	8.0954	2283.9773	0.9719	2409.2509	0.3291
	5	2298.8901	5.5947	2258.4757	11.595	2316.9138	1.0811	2429.7206	0.5770
Slice 32	2	1805.7002	1.5329	1768.2375	3.6359	1809.3391	0.3119	2607.1085	0.0000
	3	2508.9858	5.9255	2490.0134	8.9593	2550.4376	0.6319	2712.4045	0.0000
	4	2638.1503	6.0875	2622.3733	10.106	2655.9939	0.6323	2751.8314	0.4169
	5	2684.5772	8.1013	2661.26	10.4482	2704.0157	0.5234	2773.8080	1.0328
Slice 42	2	2115.5	1.1383	2114.0826	2.4257	2118.4914	0.2877	3044.4209	0.0000
	3	2844.7327	5.2362	2777.0449	11.2845	2885.6715	0.6169	3143.9107	0.0000
	4	3107.4829	7.2116	3081.1126	0.7194	3117.6145	0.8095	3199.6969	0.2542
	5	3127.2123	9.492	3096.6308	12.9111	3157.2836	1.4592	3234.6346	1.2212
Slice 52	2	1568.4215	0.6005	1567.5398	1.0676	1569.4257	0.1278	2858.8493	0.0000
	3	2043.6957	6.1261	1987.5648	8.9835	2093.4182	0.6771	2946.9059	0.0000
	4	2468.5994	8.4673	2423.131	11.62	2482.4615	1.0087	2997.4113	0.1775
	5	2897.9832	9.8968	2853.3284	14.9214	2932.8703	1.8026	3023.6302	0.8846
Slice 62	2	2156.8369	1.0589	2156.5687	1.7587	2158.5697	0.1474	3369.4257	0.0000
	3	2716.3481	6.2764	2607.6734	8.2952	2769.2768	1.0727	3484.6113	0.0000
	4	3190.5445	7.0454	3155.349	9.711	3206.0544	1.3146	3537.5265	1.5829
	5	3265.6812	9.4338	3212.7383	14.1009	3309.2357	1.9567	3578.0461	1.1802
Slice 72	2	2081.9246	1.3353	2081.111	1.6951	2082.921	0.2594	3206.1499	0.0000
	3	2253.3567	4.2687	2213.2085	7.1283	2263.0027	0.6032	3342.1458	0.0000
	4	2377.8177	6.4258	2325.6424	8.8162	2434.0122	0.8303	3405.4864	0.7525
	5	3112.1951	8.926	3073.8629	11.8514	3126.9544	1.1771	3441.5308	0.7428
Slice 82	2	1696.2301	1.553	1694.6343	3.0218	1653.4012	0.2731	2938.1252	0.0000
	3	1802.7174	4.8403	1768.1706	7.231	1818.4169	1.1472	3061.3366	0.0000
	4	2038.872	5.0545	1982.6553	8.4291	2099.9188	1.6522	3117.0742	0.3859
	5	2432.9266	7.0537	2367.9349	12.8586	2502.1594	2.1028	3151.6365	0.6426
Slice 92	2	1567.7541	1.4823	1560.844	2.5343	1612.4944	0.5419	2653.9932	0.0000
	3	1610.4358	2.2252	1566.9711	5.9533	1658.7572	1.7586	2716.0529	0.0000
	4	1906.4377	7.211	1834.7696	12.4346	1961.816	2.3913	2750.6745	1.3238
	5	1911.5765	11.5681	1847.0448	15.8281	1980.6752	2.659	2775.5395	0.908
Slice 102	2	1719.8153	1.2226	1682.6564	1.6573	1732.1681	0.2828	2571.5656	0.0000
	3	1820.0506	5.8143	1748.0404	8.4476	1842.9706	1.096	2643.6091	0.0000
	4	1946.9374	6.5418	1896.7374	11.7714	1992.9366	1.1994	2682.7476	0.9339
	5	2054.1324	7.37	2003.1268	12.9399	2111.3087	1.2690	2703.9818	0.0581
Slice 112	2	1837.9315	2.4152	1832.9201	4.7014	1843.804	0.292	2016.6101	0.0000
	3	1861.2064	4.4064	1833.1186	7.048	1896.9173	0.8327	2090.2402	0.0000
	4	1954.9194	5.6559	1935.527	8.5241	1971.2272	1.6267	2126.6682	0.3269
	5	2027.1985	6.8095	2015.7317	9.1069	2035.3337	1.8955	2141.1360	0.5412

Tabela 11: *Poređenje trešhold vrednosti dobijenih korišćenjem Otsuove metode i predloženeog algoritma slepog miša sa rezultatima iz [68]*

Slike	Th. no.	Optimalne trešhold vrednosti			
		PSO	GA	ABF	BA
Slice 22	2	94, 180	94, 184	93, 176	35, 99
	3	72, 118, 188	73, 120, 180	69, 117, 180	23, 67, 117
	4	55, 104, 155, 200	62, 109, 162, 189	50, 110, 154, 181	17, 51, 89, 128
	5	52, 98, 138, 187, 209	59, 97, 138, 162, 207	50, 86, 126, 176, 197	13, 41, 71, 103, 135
Slice 32	2	108, 186	110, 176	107, 178	43, 113
	3	73, 123, 176	75, 122, 168	70, 120, 154	23, 69, 123
	4	6, 096, 131, 180	57, 115, 162, 202	56, 96, 133, 198	19, 59, 97, 135
	5	49, 88, 127, 182, 203	55, 92, 128, 177, 205	48, 83, 119, 157, 200	17, 49, 83, 115, 150
Slice 42	2	111, 186	111, 187	112, 182	45, 121
	3	81, 125, 197	85, 128, 179	80, 122, 170	31, 81, 135
	4	62, 107, 142, 183	66, 108, 147, 188	59, 108, 144, 188	23, 67, 113, 161
	5	55, 118, 142, 170, 206	66, 98, 129, 168, 208	55, 96, 128, 158, 194	19, 55, 91, 129, 174
Slice 52	2	117, 189	117, 191	118, 188	45, 115
	3	102, 133, 174	103, 134, 176	100, 132, 171	37, 89, 133
	4	85, 123, 172, 214	88, 119, 151, 206	85, 114, 147, 184	19, 59, 97, 137
	5	66, 98, 130, 160, 216	70, 100, 126, 156, 206	60, 96, 125, 172, 197	19, 57, 94, 125, 165
Slice 62	2	118, 185	117, 185	118, 183	47, 123
	3	98, 138, 181	101, 142, 186	95, 131, 178	39, 97, 147
	4	80, 128, 156, 193	82, 115, 141, 177	80, 112, 150, 194	35, 85, 123, 168
	5	78, 107, 136, 172, 205	80, 105, 144, 186, 203	75, 106, 136, 172, 212	19, 59, 97, 133, 179
Slice 72	2	112, 168	111, 166	111, 173	45, 127
	3	106, 155, 206	107, 142, 192	105, 139, 191	41, 103, 165
	4	101, 133, 170, 208	104, 129, 162, 202	100, 128, 166, 204	37, 87, 125, 183
	5	76, 118, 141, 176, 216	78, 103, 134, 161, 205	75, 103, 132, 164, 202	21, 61, 95, 131, 185
Slice 82	2	114, 168	114, 166	115, 167	45, 124
	3	110, 166, 186	112, 144, 198	110, 141, 195	43, 105, 171
	4	101, 134, 155, 203	103, 136, 161, 207	100, 128, 162, 206	35, 83, 119, 181
	5	89, 120, 139, 164, 203	92, 114, 140, 178, 211	87, 111, 140, 185, 215	19, 58, 93, 127, 187
Slice 92	2	101, 180	101, 186	100, 182	43, 113
	3	102, 140, 173	103, 132, 172	100, 136, 194	39, 95, 137
	4	92, 120, 148, 178	93, 133, 169, 196	90, 132, 165, 191	19, 59, 99, 141
	5	91, 111, 138, 168, 197	94, 107, 135, 175, 204	90, 107, 129, 158, 196	19, 57, 90, 117, 155
Slice 102	2	100, 172	101, 170	100, 158	43, 113
	3	95, 160, 197	100, 142, 194	96, 132, 170	39, 95, 143
	4	92, 122, 162, 199	94, 120, 154, 181	90, 130, 157, 182	21, 60, 101, 147
	5	87, 115, 148, 183, 212	89, 107, 137, 175, 204	86, 108, 133, 170, 205	13, 53, 89, 111, 150
Slice 112	2	94, 173	94, 178	93, 170	41, 111
	3	78, 128, 178	79, 128, 176	76, 113, 172	27, 75, 127
	4	70, 119, 177, 200	72, 128, 162, 190	70, 108, 150, 177	23, 65, 103, 147
	5	62, 98, 136, 172, 194	63, 97, 134, 180, 200	60, 97, 140, 170, 208	17, 53, 84, 112, 153

Poređenjem rezultata dobijenih predloženom BA metodom i rezultatima iscrpnog pretraživanja može se zaključiti da je srednja vrednost svih predloženih metoda bila ista kao i optimalno rešenje (pronađeno iscrpnim pretraživanjem) u svim slučajevima. Trešhold vrednosti su u većini slučajeva iste kao i one dobijene iscrpnom pretragom, dok u slučajevima kada nisu bile iste, razlike između optimalnih i naših trešhold vrednosti su 1, što nema značajan uticaj na vrednost funkcije cilja definisanu Otsu-ovom metodom. ABF za optimizaciju Otsua koji je predložen u [68], kao i PSO i GA su bili potpuno neuspešni u pronalaženju optimalnih trešhold vrednosti, pa čak i za 3 trešhold vrednosti, dok je naš predloženi metod uspešno pronašao optimalne pragove čak i do 5 njih.

Tabela 12: *Poređenje PSNR vrednosti*

Slike	K	ABF	PSO	GA	BA	ABF	PSO	GA	BA
		Kapurova metoda				Otsu metoda			
Slice 022	2	10.3797	10.2262	9.9937	18.1832	10.0804	9.4896	9.4383	12.8036
	3	13.3339	11.1432	10.3586	20.9449	13.2461	10.9784	9.9702	14.1289
	4	14.7998	11.9115	10.8226	22.0561	14.0166	11.4129	10.4584	14.3873
	5	17.3948	12.8008	11.5242	23.9788	16.3086	11.9047	11.0710	15.1826
Slice 032	2	9.2958	9.2258	9.1659	16.6264	9.1680	8.4334	8.3401	14.4436
	3	12.0748	10.3761	10.1987	23.1916	12.0415	9.9919	9.7589	14.3840
	4	15.0312	10.8228	10.2217	22.9834	14.7071	10.8084	10.0698	15.7103
	5	16.0706	12.3663	12.0763	26.7080	15.7517	11.3651	11.0586	17.2322
Slice 042	2	9.0892	8.3232	8.0214	15.4695	9.0416	8.3074	8.0040	15.2580
	3	12.8016	12.0244	11.3524	19.4792	12.2214	11.0724	10.7629	15.9369
	4	16.0888	12.1678	11.7220	22.2615	14.8753	11.5079	11.0010	19.0272
	5	16.7785	12.2266	12.1758	24.2281	15.6372	12.0292	11.9258	19.3711
Slice 052	2	9.2423	9.0995	9.0864	14.1782	9.1512	8.2262	8.2138	14.0711
	3	10.1470	9.6239	9.2318	14.2964	9.7967	9.2269	8.5375	16.0760
	4	11.7610	10.8089	10.7900	17.8094	11.3122	10.2423	10.0703	15.1449
	5	15.8293	14.5218	13.9061	25.7108	15.2471	14.1602	13.0036	18.6706
Slice 062	2	9.2923	9.1743	9.0503	13.7767	9.1676	8.7591	8.4387	14.6307
	3	10.7920	9.9701	9.9525	15.4673	10.4215	9.1557	8.9016	17.7149
	4	11.6814	10.3589	10.2845	15.9655	10.9746	9.8815	9.7558	20.6214
	5	14.1835	11.1878	11.0900	23.3689	13.6217	11.1006	11.0333	19.6343
Slice 072	2	9.4718	9.3428	9.0592	13.8472	8.9376	8.8525	8.7345	15.5752
	3	11.0449	10.3902	10.0479	15.3521	10.5680	9.4403	9.0029	21.0261
	4	11.4977	10.6144	10.1248	14.7945	11.0596	9.9724	9.7072	22.3572
	5	12.3427	11.8184	11.3219	23.2105	11.6371	11.3969	11.3040	19.7905
Slice 082	2	9.7528	9.4186	9.4000	14.3065	9.4512	9.3187	9.3174	15.4074
	3	9.8383	9.5024	9.4449	14.8489	9.9267	9.4671	9.3559	22.3214
	4	10.9257	9.8371	9.5426	15.2241	10.8434	9.7496	9.4726	21.5294
	5	12.4152	11.9953	11.7067	22.5680	12.1136	11.9167	11.6266	19.4387
Slice 092	2	9.7164	9.3141	9.2386	14.6071	9.2776	9.2578	9.1984	14.5759
	3	10.2080	9.7189	9.2746	14.5966	9.5888	9.3256	9.2416	18.2035
	4	10.4659	9.9068	9.7617	15.1607	10.3402	9.4954	9.3816	16.2610
	5	11.0371	10.5687	10.2536	23.6398	10.6470	10.4471	10.2424	17.8356
Slice 102	2	9.3821	9.1758	9.0337	15.7343	9.3085	8.9941	8.9397	14.8725
	3	10.3549	9.4893	9.3636	16.9347	10.1409	9.3550	9.1876	19.4547
	4	11.1645	10.0271	9.6118	19.5208	11.1441	9.9774	9.2865	17.3895
	5	12.0000	10.3387	9.9717	23.8102	11.6172	10.0065	9.8121	18.4938
Slice 112	2	9.0723	8.7510	8.5102	17.1342	9.0078	8.7990	8.4614	16.1096
	3	12.4552	9.1849	9.1081	23.0228	11.9058	8.9684	8.5731	17.0199
	4	14.2680	13.3593	13.0415	21.4486	12.6892	12.4106	12.3492	19.4560
	5	15.9034	14.0073	13.3282	21.9383	14.0649	13.7907	13.0640	19.1203

Da bismo dodatno testirali kvalitet predložene metode za segmentaciju MRI slika mozga, izračunali smo odnos signala i šuma, *peak-to-signal noise ration* (PSNR).

Ova mera se obično koristi kao objektna razlika između dve slike i definiše se kao:


$$RMSE = \sqrt{\frac{1}{N * M} \sum_{i=0}^N \sum_{j=0}^M [I(i, j) - \hat{I}(i, j)]^2} \quad (76)$$

$$PSNR = 20 \log_{10} \left(\frac{255}{RMSE} \right) \quad (77)$$

gde je I originalna slika, a $\hat{I}$ označava segmentiranu sliku veličine $N \times M$. Dve slike su sličnije ako je $RMSE$ (srednja kvadratna greška) niža, gde za dve identične slike $RMSE$ je 0. Budući da je $PSNR$ definisan inverznom vrednošću $RMSE$ onda je veća i bolja vrednost. U tabeli 12 su prikaza poređenje rezultata $PSNR$ iznesenih u [68] i rezultata dobijenih predloženom BA metodom. Segmentirane slike Kapurovom metodom optimizovanom predloženom BA metodom sličnije su njihovim odgovarajućim izvornim slikama. Kada se Otsuova metoda koristi za segmentaciju, samo u slučaju 5 trešhold vrednosti za *Slice 22*, ABF je postigao bolju vrednost za $PSNR$. U svim drugim slučajevima BA je nadmašio ABF, PSO i GA. Pošto se $PSNR$ može shvatiti kao vizuelni kvalitet segmentiranih slika, može se zaključiti da predloženi metod obezbeđuje bolju segmentaciju u odnosu na metode koje koriste ABF, PSO i GA za optimizaciju Kapura i Otsua.

Segmentacija slike *Slice 22* sa trešhold vrednostima dobijenim predloženom BA metodom (korištenjem Kapurove i Otsuove metode) prikazana je na slici 35.

U ovom istraživanju predložili smo metodu za segmentaciju MRI slika mozga što predstavlja važan zadatak za bržu i tačniju analizu i dijagnostiku [25]. Predložili smo segmentaciju dobro poznatom Kapurovom metodom i Otsuovom metodom za pronalaženje optimalnih trešhold vrednosti. Kapurov i Otsuov metod su optimizovani prilagođenim algoritmom inteligencije rojeva, algoritmom slepog miša. Kvalitet predloženog algoritma testiran je na standardnim test slikama. Rezultati su upoređeni sa rezultatima postignutim sa četiri različita algoritma za optimizaciju iz literature: genetski algoritam, optimizacija rojem čestica, adaptivna bakterijska ishrana i genetski algoritam sa realnim kodiranjem rešenja. Predloženi algoritam je postigao bolje rezultate u odnosu na pomenute algoritme, pronašao preciznije trešhold vrednosti u odnosu na stvarne vrednosti dobijene iscrpnim pretraživanjem, i pri tome je imao najmanju standardnu devijaciju prilikom višestrukog pokretanja metode.



Slika 35: *Segmentacija slike Kapurovom i Otsuovom metodom*

8.3 Frekventne komponente i kompresija slika

Medicinske slike moraju biti u visokoj rezoluciji, a jedna slika može da sadrži milione piksela što zahteva više od deset megabajta memorije. Da bi se smanjio prostor potreban za skladištenje medicinskih digitalnih slika mogu se primeniti različite metode kompresije.

Jedan od dobro poznatih i široko korišćenih algoritama kompresije sa gubitcima je JPEG koji može smanjiti prostor potreban za čuvanje informacija o slici dvadeset ili čak pedeset puta [34]. Glavna redukcija prostora potrebnog za čuvanje slike se postiže korakom kvantizacije koji odbacuje manje važne podatke pomoću kvantizacionih tabele. JPEG standard sadrži preporučene tabele kvantizacije, ali medicinske digitalne slike su prilično specifične, tako da se bolji rezultati mogu postići podešavanjem kvantizacionih tabela za svaku klasu slika posebno. Pronalaženje optimalnih elemenata kvantizacione tabele je kombinatorni problem pošto 64 elementa mogu uzeti bilo koju vrednost od nekog specifičnog opsega koji je, u praksi, [1, 255]. Deterministički metod je isprobavanje svih mogućih kombinacija što nije moguće u razumnom vremensko periodu.

Za selekciju kvantizacionih tabela primenjeni su algoritmi inspirisani prirodom, npr. [52], [49], optimizacija roja čestica [56], algoritam svitca [92], algoritam za optimizaciju bakterijskog hranjenja [27], algoritam vođen vatrometom [90]. Kratak pregled algoritama za inteligenciju roja koji su predloženi za prilagođavanje JPEG algoritma dat je u [97].

U ovom istraživanju smo prilagodili poslednju verziju algoritma vatrometa, BBFWA, za selekciju kvantizacione tabele za kompresiju medicinskih slika. Rezultati ovog istraživanja su opisani i objavljeni u [86]. Cilj je postići isti nivo kompresije kao onaj koji se dobija preporučenim kvantizacionim tabelama, ali sa boljim kvalitetom što je od izuzetnog značaja za medicinske slike. Pošto su kvantizacione tabele veličine 8×8 , dimenzija problema je 64, tj. ulazni vektor za BBFWA predstavlja 64 elementa kvantizacione tabele koje treba odredi. Teorijske granice za DCT koeficijente su 1 i 1023, ali u praksi su retko veće od 255, tako da je raspon elemenata kvantizacione tabele postavljen da bude [1, 255]. Elementi kvantizacione tabele su celi brojevi, dok BBFWA koristi realne brojeve tako da smo algoritam prilagodili na sledeći način. Korišćen je redovni BBFWA, ali su dobijena rešenja (elementi vektora) zaokružena na najbliži ceo broj.

Nivo kompresije koji se želi postići može se definisati na razne načine. U ovom radu se smatra da se isti nivo kompresije postiže sa kvantizacionim tabelama čije su sume elemenata jednake. Uvođenjem ovog uslova, razmatrani problem postaje problem optimizacije sa ograničenjima. Štaviše, ovo je najteže ograničenje, ograničenje

jednakosti, jer je pronalaženje dozvoljenog rešenja gotovo nemoguće. Obično se ovaj problem rešava uvođenjem parametra tolerancije koji će u početku biti veći da bi u kasnijim fazama algoritma bio sveden na nulu. Za razmatrani problem, može se primeniti još lakše rešenje: ograničenje jednakosti se lako može pretvoriti u nejednakost. Ako je suma elementa kvantizacione tabele veća ili jednaka nekoj konstanti, tada će se dobiti veći ili isti nivo kompresije. Imajući u vidu da veća kompresija znači niži kvalitet, BBFWA algoritam će konvergirati ka rešenjima koja će zadovoljiti (ili skoro zadovoljiti) ograničenje jednakosti problema optimizacije zato što funkcija cilja predstavlja kvalitet kompresovane slike.

Iako se ublažavanjem ograničenja proširio skup dopustivih rešenja, BBFWA algoritam neće uvek generisati neko od njih, odnosno dešavaće se da bude generisano nedopustivo rešenje što u ovom konkretnom slučaju znači kvantizaciona matrica čija je suma elemenata veća od date konstante. Iz ovog razloga je neophodno definisati poređenje između rešenja i mehanizam za rukovanje nedopustivim rešenjima. Za poređenje dva rešenja, koristili smo Debova pravila, tj. dopustivo rešenje je uvek bolje od nedopustivog, nedopustivo rešenje koje manje krši ograničenje se smatra boljim kada se porede dva nedopustiva rešenja i, na kraju, između dva dopustiva rešenja, bolje je ono sa boljom vrednošću funkcije cilja. U konkretnom primeru, rešenje sa sumom elemenata koje je bliže datoj konstantnoj manje narušava ograničenje. Pošto je izračunavanje funkcije cilja prilično skupa operacija, jer uključuje kompresiju i dekompresiju, rešenja koja imaju zbir elemenata manji od datog broja nisu uzeta u obzir, već se generiše novo rešenje.

Kvalitet kompresovane slike može se meriti na različite načine, a neke od uobičajenih metrika su srednja kvadratna greška i normalizovana unakrsna korelacija. Ova dva merenja predstavljaju razliku između originalne i kompresovane slike. Srednja kvadratna greška (engl. mean square error, MSE) je definisana na sledeći način:

$$MSE = \frac{1}{NM} \sum_{i=1}^N \sum_{j=1}^M (x_{i,j} - x'_{i,j})^2 \quad (78)$$

gde su $x_{i,j}$ i $x'_{i,j}$ vrednosti intenziteta piksela (i, j) u, redom, originalnoj i kompresovanoj slici, dok su M i N dimenzije slike. Za dve identične slike, MSE je jednaka 0 i što su dve slike različitije to je vrednost MSE veća, što znači da je cilj je minimizovati MSE. Često se koristi i jedna metrika koja se definiše pomoću MSE, pa smo je


uključili u ovo istraživanje. Odnos signala prema šumu (PSNR) definisana je ranije i korišćena za proveru kvaliteta segmentiranih MRI slika mozga.

Normalizovana unakrsna korelacija (NK) je druga funkcija fitnesa koja se koristi u ovom radu za određivanje kvaliteta komprimovane slike:

$$NK = \frac{\sum_{i=1}^N \sum_{j=1}^M x_{i,j} x'_{i,j}}{\sum_{i=1}^N \sum_{j=1}^M x_{i,j}^2} \quad (79)$$

Najbolja vrednost za NK je 1 koja se dobija za dve identične slike. Manje slične slike će imati vrednosti NK manje od 1 pa je prema tome cilj maksimizovati NK što je isto što i minimizacija -NK vrednosti.

Parametri za BBFWA su podešeni na sledeći način. Veličina populacije je bila 200, maksimalni broj evaluacija fitnes funkcije je bio 10000. Parametri C_a i C_r su postavljeni na 1.2, odnosno 0.7, redom.




Slika 36: *Originalne test slike*

Mi smo testirali naš predloženi BBFWA algoritam na standardnim MRI slikama mozga koje su dostupane i slobodne za upotrebu [42], fantomska ultrazvučna slika javno dostupna na www.iezitronik.com/kidnei_phantom.html i slika dobijena endoskopskom kapsulom [19]. Slike koje se koriste u ovom radu prikazane su na slici 36.

Tabela 13: *Kvantizacionim tabela Q_{10} (levo) and Q_{10_opt} optimizovana BBFWA (desno)*

80	55	50	80	120	200	255	255	7	5	15	39	238	239	153	255
60	60	70	95	130	255	255	255	8	13	17	56	136	230	255	255
70	65	80	120	200	255	255	255	10	13	15	196	214	255	255	255
70	85	110	145	255	255	255	255	34	36	245	226	255	255	255	255
90	110	185	255	255	255	255	255	159	247	236	255	255	255	255	255
120	175	255	255	255	255	255	255	194	223	255	255	255	255	255	255
245	255	255	255	255	255	255	255	241	255	255	255	255	255	255	255
255	255	255	255	255	255	255	255	255	255	255	255	255	255	255	255

Kvalitet predloženog prilagođenog BBFWA algoritma će biti demonstriran na MRI slici mozga. Prvo smo testirali predloženi algoritam za veći nivo kompresije. Koristili smo preporučenu tabelu kvantizacije Q_{10} . Predloženi BBFWA je korišćen za pronalaženje optimalnih elemenata kvantizacione tabele Q_{10_opt} uz uslov da bude zadržan isti nivo kompresije na način opisan ranije. Koristili smo MSE kao funkciju cilja i rezultujuća kvantizaciona tabela zajedno sa preporučenom su prikazane u tabeli 13.



Slika 37: Dekompresovane slike standardnom Q_{10} kvantizacionom tabelom (levo) i tabelom Q_{10_opt} (desno) dobijenu BBFWA (fitnes funkcija je MSE)

Preporučena kvantizaciona Q_{10} i kvantizaciona tabela dobijena predloženim algoritmom su veoma različite i to se razlikuju u elementima iznad anti-dijagonale. Svi elementi ispod anti-dijagonale su 255. Naš predloženi BBFWA otkrio je da je bolje sačuvati DCT koeficijente u gornjem levom uglu (niže frekvencije). Suma elemenata u Q_{10_opt} je 12.625 što je za 13 veće od sume elemenata u Q_{10} (12.612), tako da je čak i sa većom kompresijom dobijena vizuelno bolja slika što se može videti na slici 37. Razlika je posebno vidljiva za endoskopsku sliku. Štaviše, MSE za MRI sliku mozga kada se koristi Q_{10} tabela je 83.0964 dok je MSE za sliku

kompresovanu kvantizacionom tabelom dobijenom predloženom metodom, 52.5501, što je značajno bolje. Slična situacija je i sa ultrazvukom i endoskopskom slikom. Za sliku ultrazvuka i Q_{10} , MSE je bio 59.0486 dok je sa Q_{10_opt} MSE smanjen na 23.7515. MSE za endoskopsku sliku i Q_{10} je bio 19.6122 dok je sa optimizovanom Q_{10_opt} bio samo 5.7582.


U drugom eksperimentu, testirali smo nivo kompresije koji je dobijen pomoću Q_{20} kvantizacione tabele. Za ovaj nivo kompresije, razlika između dekompresovanih slika nije tako očigledna, ali s obzirom na to da se danas većina medicinskih slika automatski obrađuje na računaru, sličnost u terminima različitih metrika kao što su MSE, PSNR i NK su važnije od sličnosti prema vizuelnom osećaju čoveka. Kvantizacione tabele Q_{20} (preporučene od strane JPEG standarda) i Q_{20_opt} dobijene pomoću BBFWA postižu isti nivo kompresije i prikazane su u tabeli 14. Dekompresovane slike su prikazane na slici. 38.

Tabela 14: *Kvantizacionim tabela Q_{20} (levo) and Q_{20_opt} optimizovana BBFWA (desno)*

40	28	25	40	60	100	128	153	2	3	13	13	14	245	114	238
30	30	35	48	65	145	150	138	4	6	2	4	12	17	57	255
35	33	40	60	100	143	173	140	6	11	5	8	16	5	255	255
35	43	55	73	128	218	200	155	11	13	3	139	5	255	255	255
45	55	93	140	170	255	255	193	131	119	7	233	255	255	255	255
60	113	138	160	203	255	255	230	81	9	245	255	255	255	255	255
123	160	195	218	255	255	255	253	71	188	255	255	255	255	255	255
180	230	238	245	255	250	255	248	188	255	255	255	255	255	255	255

U ovom eksperimentu, tabele kvantizacije koje postižu isti nivo kompresije su značajno različite. Suma elemenata u Q_{20} je 9326 što je opet malo manje od sume elemenata u Q_{20_opt} dobijene predloženim BBFWA gde je suma 9378. MSE za kompresovanu MRI sliku mozga sa Q_{20} je 45.0917 dok je pomoću predložene metode dobijena kvantizaciona tabela Q_{20_opt} tabele kvantizacije sa kojom se MSE smanjuje na 22.3347 što je više nego dvostruko poboljšanje. Za ultrazvučnu sliku, MSE je smanjen sa 30.1042 na 13.0285 ako se koristi optimizovana kvantizaciona tabela, dok je u slučaju endoskopske slike, MSE sa standardnom kvantizacionom tabelom 9.0847, a sa optimizovanom 3.0428.

Svi rezultati su sumirani u tabeli 15. Predloženi metod je nadmašio standardni JPEG algoritam za sve test slike i za sve korišćene metrike.



Slika 38: Dekompresovane slike standardnom Q_{20} kvantizacionom tabelom (levo) i tabelom Q_{20_opt} (desno) dobijenu BBFWA (fitnes funkcija je MSE)

Tabela 15: Poređenje različitih mera sličnosti dobijenih preporučenim kvantizacionim tabelama i tabelama dobijenim predloženim BBFWA


Image	MSE		PSNR		NK	
	Q_{10}	Q_{BBFWA}	Q_{10}	Q_{BBFWA}	Q_{10}	Q_{BBFWA}
Slice 022	83.0964	52.5501	30.3999	30.9251	0.9832	0.9894
Ultrazvuk	59.0486	23.7515	30.4187	34.3739	0.9880	0.9951
Endoskopija	19.6122	5.7582	35.2055	40.5280	0.9978	0.9994
Image	MSE		PSNR		NK	
	Q_{20}	Q_{BBFWA}	Q_{20}	Q_{BBFWA}	Q_{20}	Q_{BBFWA}
Slice 022	45.0917	22.3347	31.5898	34.6410	0.9907	0.9955
Ultrazvuk	30.1042	13.0285	33.3445	36.9819	0.9939	0.9973
Endoskopija	9.0847	3.0428	38.5477	43.2981	0.9990	0.9997

8.4 Detekcija krvarenja na EC slikama

Bežična kamera koja je smeštena u endoskopsku kapsulu (engl. capsule endoscopy, CE) prikuplja slike u boji. Ta činjenica omogućava korišćenje komponenti boje iz različitih sistema kojima se mogu otkriti više detalja nego u slučaju crno-belih slika. Lekari takođe koriste karakteristike boje i teksture prilikom pregleda slika, što predstavlja osnovu za korišćenjem ovih osobina i u automatskim analizama rađenim

na računarima koji služe za otkrivanje abnormalnosti, posebno krvarenje.

U kompjuterskoj grafici se koriste različiti prostori boja. Prilikom ispitivanja karakteristika boja, prvi zadatak je da izaberete odgovarajući prostor boja. U ovom istraživanju koristimo HSI prostor boja. Na slikama su prikazani primeri CE slika sa krvarenjem. Može se videti da je boja krvi jarkija od boje tkiva. Ta razlika se najbolje vidi u komponenti zasićenosti HSI modela tako da smo je koristili kao ključnu komponentu u našem predloženom pristupu. Druga razlika je u intenzitetu boje. Koristili smo kanal intenziteta za izdvajanje karakteristika teksture. U ovom radu koristili smo uniformni lokalni binarni obrazac (LBP) za opisivanje teksture. Deo ovog istraživanja je objavljen na međunarodnoj konferenciji [88].



Slika 39: *Primer CE slika sa krvarenjem*

U našem predloženom algoritmu izračunali smo histogram za uniformne LBP uzorke na regionima 8×8 . Dimenzija regiona je određena empirijski. U ovom istraživanju smo testirali srednju vrednost, varijansu, asimetričnost, kurtozu, energiju i entropiju LBP histograma. Klasifikacija je izvršena za sve regione te veličine na slici. Za svaki region određen je uniformni lokalni binarni obrazac i prosečna zasićenost. Ove karakteristike su korišćene kao ulazne karakteristike za SVM. Model mašine potpornih vektora je istreniran da obeležava regione kao region sa ili bez krvarenja ili kao pozadina. Za ulaznu sliku svi regioni 8×8 će biti označeni.

Ova procedura rezultira segmentacijom slike na nivou regiona, što je za medicinske svrhe često ne dovoljno kvalitetno i precizno. Dalja analiza poboljšava kvalitet segmentacije do segmentacije na nivou piksela. Za to je korišćen sistem glasanja. Osim piksela na ivici, svaki piksel pripada 64 različitih regiona. Piksel će dobiti oznaku na osnovu većine oznaka regiona kojima pripada. U slučaju nerešenog rezultata, razmatraju se samo susedni pikseli. Za piksele uz rub slike smo koristili

istu proceduru, ali njihova većina nije 33 kao u prethodnom slučaju. U zavisnosti od pozicije na ivici može da pripada samo jednom, dva ili više regiona.

Predložena metoda opisana algoritmom 8.

Algorithm 8 Predloženi algoritam za detekciju krvarenja na CE slikama

Ulaz: CE slika

Korak 1: *Priprema:* Prebaci sliku iz RGB modela u HSI model boja;

Korak 2: *Izračunavanje karakteristika:* Za regione 8×8 izračunaj prosečnu zasićenost i karakteristike LBP histograma;

Korak 3: *Klasifikacija regiona:* Svaki region je klasifikovan kao krvarenje, region bez krvarenja ili kao pozadina koristeći SVM;

Korak 4: *Klasifikacija na nivou piksela:* Svaki piksel je klasifikovan u jednu od tri klase na osnovu klase regiona kojim pripada.

Izlaz: Segmentirana CE slika

U ovom radu za ispitivanje predloženog algoritma korišćeno je 50 CE slika sa krvarenjem. Skup podataka je besplatan i dostupan na internetu [19]. Pored CE slika, u ovom skupu podataka dati su i rezultati segmentacije eksperata. Za obuku SVM-a korišćeno je 100 regiona svake klase (krvarenje, ne-krvarenje i pozadina). Regioni za trening skup su generisani nasumično. Tačnost odabira regiona neke klase je kontrolisano pomoću slika koje su dostupne uz bazu. Nakon što je SVM model izgrađen, sve slike su segmentovane korišćenjem tog modela.

Da bi se izmerila tačnost predložene metode korišćeno je nekoliko mera kvaliteta. Ove metrike su korišćene i u [20]. Prva metrika je koeficijent sličnosti dice (engl. dice similarity coefficient, DSC) [22]. Ovaj koeficijent predstavlja indeks prostornog preklapanja koji daje merenje sličnosti između dve segmentovane slike. U našem slučaju, slika dobijena našim predloženim metodom upoređena je sa slikom segmentiranom od strane eksperta, takozvane *ground-truth* slike. DSC definisan je sledećom jednačinom:

$$DSC = \frac{2 \cdot |F_g \cap F_t|}{|F_g| + |F_t|} \quad (80)$$

gde je F_g piksel ground-truth slike i F_t je piksel test slike, $|x|$ predstavlja kardinalnost skupa. Ako je DSC jednak 1, segmentacija je savršena.

Druga metrika procene kvaliteta segmentacije koja je korišćena je procenat pogrešne klasifikacije (engl. missclassification error, ME). Ova metrika zapravo izračunava procenat pogrešno klasifikovanih piksela. Definicija ove metrike je data

sledećom jednačinom:

$$ME = 1 - \frac{|B_g \cap B_t| + |F_g \cap F_t|}{|B_g| + |B_t|} \quad (81)$$

gde B_t i F_t predstavljaju piksele pozadine i objekata na test slici, dok su slično B_g i F_g pikseli ground-truth baze. Tačnost segmentacije je maksimalna u slučaju kada je ME jednak 0.

U tabeli 16 su prikazane prosečne vrednosti i standardne devijacije za ranije navedene osobine. Ove karakteristike su izračunate za instance trening skupa. U prvoj koloni prikazane su je srednje vrednosti i standardne devijacije za primere koji pripadaju klasi krvarenja, u drugoj koloni su karakteristike za klasu regiona bez krvarenja i u poslednjoj koloni za instance pozadine. Na osnovu rezultata ovog eksperimenta može se izvršiti selekcija nekih karakteristika.

Kao što se može videti, prosečna zasićenost regiona je veoma različita za instance između klasa, ali je takođe i standardna devijacija za svaku klasu mala, što znači da su unutar klasa instance veoma slične. Ovo kvalifikuje ove karakteristike regija za jednu od osobina koje će se koristiti kao ulaz za SVM. Sa druge strane, srednja vrednost i standardna devijacija LBP histograma su veoma slične za regione sa krvarenjima i bez, dok se regioni pozadine lako razlikuju. Za svaku testiranu karakteristiku pozadina je jasno različita od stvarnog tkiva i zbog toga se svaka karakteristika može koristiti za odvajanje pozadine od tkiva. Može se pretpostaviti da bi se regioni sa i bez krvarenja mogli razlikovati po teksturi krvi i tkiva, ali ovaj eksperiment pokazuje da to nije sasvim tačno. Ove dve karakteristike ne pružaju dovoljno informacija.

Na osnovu informacija u tabeli 16 pokušali smo segmentaciju sa SVM gde je samo prosečna zasićenost korišćena kao karakteristika regiona. Iako razlika između regiona sa i bez krvarenja izgleda dovoljno dobro u teoriji, to nije bilo dovoljno u praksi. Na slici 40 prikazana je segmentacija kada je jedna karakteristika, prosečna zasićenost, korišćena kao ulaz za SVM. Segmentacija nije obavljena kako treba. Za prikazani primer DSC je 0.7772 i ME je 0.1096 što nije dobar rezultat. Ovo dokazuje da se prosečna zasićenost ne može koristiti kao jedina ulazna karakteristika, ali takođe pokazuje da je dobar kandidat. Glavni problem ostaje da se pronađu dobre karakteristike za opisivanje regiona sa i bez krvarenja. U slučaju prosečne vrednosti asimetrije i kurtosisa postoji razlika, ali u oba slučaja, standardna devijacija je

Tabela 16: *Poređenje karakteristika za različite klase regiona*

		krv	bez krvi	pozadina
Prosečna zasićenost	avg	0.7033	0.2806	1.0000
	std	0.1560	0.0825	0.0000
LBP prosek	avg	0.0073	0.0075	0.0039
	std	0.0011	0.0011	0.0001
LBP st. devijacija	avg	0.2565	0.2587	0.2500
	std	0.0068	0.0072	0.0000
LBP asimetrija	avg	14.0695	13.5367	15.9046
	std	1.2236	1.2801	0.0108
LBP kurtosis	avg	211.1966	198.2581	253.9702
	std	30.8064	32.1944	0.2311
LBP energija	avg	0.3418	0.3344	0.9957
	std	0.0992	0.1063	0.0334
LBP entropija	avg	2.4883	2.3968	0.0167
	std	0.5055	0.5998	0.1291

relativno velika. Možemo da vidimo da vrednosti imaju preklapajuće intervale. Ove dve karakteristike se mogu koristiti, ali sa nekim dodatnim karakteristikama, dok je prosečna zasićenost već potvrđena kao potencijalno dobar kandidat.

**Slika 40:** (a) *Segmentacija CE slika koristeći samo prosečnu zasićenost*, (b) *ground truth*

Predloženi metod je upoređen sa metodom iz [20] gde je predstavljen algoritam segmentacije zasnovan na *GrowCut* za detekciju krvarenja u CE slikama. Umesto postavljanja semena od strane korisnika, predložen je automatizovani *GrowCut* (AGC) algoritam koji je koristio algoritam klasterisanja za inicijalizaciju početnih semena. U početku je slika grubo podeljena tako što se podelila na 5 do 15 klastera. Nakon toga je optimalni broj klastera dobijen po Davies-Bouldinovom kriterijumu. Centroidi klastera koji su kasnije označeni kao krvarenje, bez-krvarenja i pozadina od strane SVM klasifikatora su korišćeni kao seme. Pikseli koji imaju RGB komponente oko ovih centroida unutar određenog praga takođe su korišćeni kao seme za segmentiranje

GrowCut metodom, ali ne pre koraka za redukciju broja semena. U ovom koraku korišćena je trešhold vrednost za odbacivanje pogrešno označenih semena. Klaster koji ima manje semena od te vrednosti više se ne smatra semenom.

Naš predloženi algoritam koristi samo 3 jednostavne karakteristike kao ulaz za SVM klasifikator optimizovan metodom mreže pretrage i algoritmom slepog miša. Segmentacija je kasnije izvršena korišćenjem SVM modela koji je prethodno izgrađen.

Naš predloženi metod, iako koristi prilično jednostavne karakteristike, bio je u stanju da nadmaši komplikovanije metode iz literature. U tabeli 17 su prikazane vrednosti za DSC (najbolji rezultati su podebljani).

Tabela 17: *Poređenje vrednosti DSC dobijene predloženim algoritmom (Grid-SVM) i metodom iz [20]*

	AGC	Grid-SVM1	Grid-SVM2	BA
Min	0.62	0.65	0.66	0.68
Max	0.97	0.97	0.98	0.98
Average	0.81 ± 0.09	0.82 ± 0.11	$0.84 \pm \mathbf{0.10}$	$\mathbf{0.85} \pm 0.13$

U prvoj koloni nalaze se rezultati iz [20]. Pretposlednje dve kolone predstavljaju rezultate dobijene predloženom metodom u prvoj i drugoj fazi mreže pretrage. U prvoj fazi pretraživanja mreže najbolje vrednosti parametara bile su $C = 2^{14}$ i $\gamma = 2^{-12}$. U drugoj fazi, najbolje odgovaralo je $C = 2^{13.5}$ i $\gamma = 2^{-12}$ sa prosečnom tačnošću od 98.44%. Kao što se može videti, predloženi metod je postigao prosečan DSC 0.84, dok je u [20] najbolji DSC 0.81. Ovi rezultati su prijavljeni u [88]. Istraživanje je kasnije nastavljeno i umesto mreže pretrage za određivanje optimalnih metaparametara mašine potpornih vektora, koristili smo algoritam slepog miša. Ti rezultati su predstavljeni u poslednjoj koloni tabele 17.


U tabeli date su vrednosti za 18 za ME. Naš predloženi algoritam postigao je prosečan ME niži od pomenute metode iz literature [20] (savršena segmentacija je za $ME = 0$).

Tabela 18: *Poređenje ME dobijene predloženom metodom i metodom iz [20] (AGC)*

	AGC	Grid-SVM1	Grid-SVM2	BA
Min	0.009	0.009	0.007	0.008
Max	0.246	0.219	0.196	0.121
Avg	0.095 ± 0.05	0.095 ± 0.05	$\mathbf{0.093} \pm \mathbf{0.04}$	$\mathbf{0.092} \pm 0.07$

Metod predstavljen u [20] je bio upoređen sa drugim metodama iz literature i

pokazao značajno bolje rezultate u poređenju sa [113]. Na osnovu toga i rezultata u tabelama 17 i 18, možemo zaključiti da je naš predloženi metod za detekciju krvarenja u CE slikama pomoću mašina potpornih vektora i karakteristika boje i teksture veoma efikasan jer dobija komparativne rezultate koristeći prilično jednostavne osobine. Greška je dodatno smanjena dodavanjem algoritma inteligencije rojeva, BA (poslednja kolona u tabeli 18).



Slika 41: *Segmentaija predloženom metodom: (a) CE slika, (b) ground truth i (c)rezultujuća segmentacija*

Na slici 41 prikazani su primeri segmentacije našim predloženom algoritmom. *Ground truth* slike označavaju samo krvarenje, dok naš predloženi metod razlikuje krvarenja, regione bez-krvarenja i pozadinu. Crni delovi su pozadina, sivo tkivo koje

ne krvari i bela predstavlja krvarenje. Na slici 41 se može videti vizuelni kvalitet predložene metode. Segmentacija sa našim predloženim algoritmom je bila veoma slična segmentaciji eksperata. Neke manje razlike mogu se videti na rubovima.

8.5 Detekcija leukemije na mikroskopskim slikama

Leukemija ili rak krvi se manifestuju velikim brojem nezrelih belih krvnih zrnaca koje se nazivaju i *ćelije leukemije*. Postoje četiri osnovna tipa leukemije: akutna limfoblastna leukemija (ALL), akutna mijeloidna leukemija (AML), hronična limfocitna leukemija (CLL) i hronična mijeloidna leukemije (CML). Glavna razlika između ovih tipova je brzina napredovanja bolesti i mesto gde se ona razvija. U ovom istraživanju smo se fokusirali na detekciju ALL na mikroskopskim slikama.

ALL je vrsta leukemije u kojoj koštana srž proizvodi abnormalne odnosno nerazvijene (nepotpuno formirane) bela krvna zrnca koje se ne mogu boriti protiv infekcija, što je njihova glavna svrha. Broj abnormalnih ćelija (ćelija leukemije) brzo raste i šire se u druge organe i tkiva kao što su mozak i jetra.


Rana dijagnoza ALL je ključna za oporavak pacijenta i određivanje tretmana. ALL se može pomešati sa groznicom ili anemijom, jer imaju slične simptome pa dijagnostikovanje ove vrste leukemije može biti veoma teško. Kako bi se osigurala brza, tačna i rana dijagnoza ALL, predložene su brojne tehnike automatske obrade digitalnih slika snimljenih pod mikroskopom.

Automatska detekcija leukemije, posebno ALL, je aktivna istraživačka tema i predložene su brojne metode poslednjih godina. Uobičajeni koraci ovih metoda uključuju korak prerade, pri čemu se bela krvna zrnca ekstrakuju iz mikroskopske slike, nakon čega sledi korak ekstrakcije karakteristika. Karakteristike koje se koriste za opisivanje krvnih ćelija su boja, oblik i/ili tekstura. Kada se izabere odgovarajući skup karakteristika, poslednji korak je klasifikacija detektovanih ćelija na osnovu tih karakteristika. U ovom koraku mogu se koristiti različiti klasifikatori, a neki od najčešćih su naivni Bajesov klasifikator, k-najbližih suseda, veštačke neuronske mreže, mašina potpornih vektora, itd.

U ovom istraživanju predložena je metoda za klasifikaciju normalnih belih krvnih zrnaca i ćelija leukemije. Karakteristike oblika i teksture koriste se za opisivanje ćelija koje su segmentirane morfološkim operacijama u koraku predprocesiranja. Izabrane

karakteristike predstavljaju ulazni vektor za mašinu potpornih vektora koja se koristi za klasifikaciju krvnih ćelija kao normalne ili ćelije leukemije.

Automatska detekcija ALL na mikroskopskim digitalnim slikama predstavlja prilično složen problem i svi navedeni koraci (predprocesiranje, izdvajanje karakteristika i klasifikacija) moraju biti pažljivo analizirani i odabrani. Na osnovu najsavremenijih metoda i hematoloških procedura može se zaključiti da se prilikom analize krvnih ćelija moraju uzeti u obzir različiti faktori kako bi se dobila dobra klasifikacija normalnih ćelija i ćelija leukemije. Primer zdravih i abnormalnih (ćelija leukemije) belih krvnih zrnaca korišćene iz standardne test baze mikroskopskih slika belih krvnih zrnca, ALL-IDB2 [51], prikazan je na slici 42.




Slika 42: *Primer slika belih krvnih zrnaca iz ALL-IDB2 baze (a-b) normalna and (c-d) ćelija leukemije*

Normalne leukocite, odnosno potpuno formirana bela krvna zrnca, obično imaju jezgra u centru ćelija, malu količinu citoplazme i pravilan oblik kruga. S druge strane, ćelije leukemije imaju nepravilan oblik, jezgra pomerena od centra, veću količinu citoplazme i različitu teksturu od normalne ćelije. Zbog ovih razlika, može se pretpostaviti da deskriptori oblika i teksture mogu biti odgovarajuće karakteristike za detekciju ćelija leukemije.

Generalno, kompjuterski podržani dijagnostički sistemi (engl. computer aided diagnostic system, CAD) za ALL detekciju implementiraju tri koraka: segmentaciju gde se leukociti (bela krvna zrnca) detektuju na mikroskopskim slikama krvi, ekstrakcija karakteristika gde se biraju deskriptori oblika i teksture za opisivanje detektovanih ćelija i poslednji korak je klasifikacija.

Prvi korak u ALL detekciji je pronalaženje leukocita. Segmentacija je izvršena u HSI prostoru boja, jer su razlike između belih krvnih zrnaca i ostatka mikroskopske slike krvi vidljivije nego u RGB prostoru. Slika 43 pokazuje HSI komponente normal-


nih leukocita i ćelija leukemije. Kao što se može videti, intenzitet ne može razlikovati različite tipove krvnih ćelija, pa se neće koristiti u ovom istraživanju. Normalni leukociti mogu da se detektuju sa komponentom S (zasićenost) i komponentom H (boja), ali u slučaju ćelije leukemije najbolja segmentacija se može postići kombinovanjem ove dve komponente.



Slika 43: *Komponente HSI modela boja mikroskopskih slika krvnih zrnaca: normalnih (levo) i ćelije leukemije (desno)*

Za segmentaciju, tj. izdvajanja leukocita, empirijski smo utvrdili da su trešhold vrednosti za komponente H i S 0.3 (obe komponente su u intervalu $[0,1]$). Cela

ćelija će biti izdvojena primenom trešhold vrednosti na komponentu boje, dok se jezgro ćelije izdvaja primenom trešhold vrednosti na komponentu zasićenosti (S). Za preciznije izdvajanje jezgra i ćelija dodatno se koriste morfološke operacije. Nakon segmentacije primenjuje se morfološka operacija otvaranja sa maskom veličine 6x6. Jednom kada se odrede jezgro i ćelija, citoplazma se može dobiti uklanjanjem jezgra iz ćelije. Primer segmentacije prikazan je na slici 44.



Slika 44: *(a),(d) ćelije, (b),(e) jezgra i (c),(f) citoplazma*

Hematolozi razlikuju normalne leukocite od ćelija leukemije na osnovu oblika, boje i teksture. Pronalaženje dobrih deskriptora za ove osobine, ključna je za stvaranje dobrog CAD. Karakteristike boje su već korišćene za dekompoziciju ćelije (za izdvajanje jezgra i citoplazme).

U ovom radu obuhvaćeno je nekoliko deskriptora oblika, kao što su površina, odnos površine citoplazme prema jezgru i odnos površine jezgre prema ćeliji, perimetar i oblast. Površina predstavlja broj piksela u ćeliji, a perimetar je maksimalna udaljenost između para piksela na granici jezgra. Meri se oblast jezgra i predstavlja važnu karakteristiku obzirom da ćelije leukemije su manje zaobljene od normalnih ćelija. Zaobljenost predstavlja funkciju perimetra i površine.

$$circ = \frac{4\pi A}{P^2} \quad (82)$$

gde je P perimetar dok je A površina ćelija.

Pored karakteristika oblika, koristili smo i uniformni lokalni binarni uzorak (LBP) kao deskriptor teksture odnosno korišćene su karakteristike histograma LBP-a opisanim ranije. Za izbor konfiguracije SVM-a koristili smo maksimalno uprošćen algoritam vatrometa, BBFWA.

Da bismo analizirali tačnost klasifikacije, koristili smo standardne metrike za algoritme mašinskog učenja kao što su osetljivost (engl. *sensitivity*), specifičnost (engl. *specifity*) i tačnost (engl. *accuracy*). Prvo je potrebno generisati matricu konfuzije (engl. *confusion matrix*) pa se na osnovu nje mogu izračunati pomenute metrike. Matrica konfuzije sadrži podatke o stvarno pozitivnim (engl. *true positive*, TP), stvarno negativnim (engl. *true negative*, TN), lažno pozitivnim (engl. *false positive*, FP) i lažno negativnim (engl. *false negative*, FN) klasifikacijama. Ako posmatramo klasu kojoj pripadaju ćelije leukemije i nju obeležimo kao pozitivnu klasu, a normalne bele ćelije pripadaju negativnoj klasi, onda TP predstavlja broj ispravno klasifikovanih ćelija leukemija, dok je FN broj ćelije leukemije klasifikovanih kao normalne ćelije i slično važi za TN i FN. Nakon određivanja matrice konfuzije, osetljivost i specifičnost izračunavaju se na osnovu sledećih formula:

$$Sensitivity = \frac{TP}{TP + FN} \quad (83)$$

$$Specificity = \frac{TN}{TN + FP} \quad (84)$$

Osetljivost, koja se naziva i stopa stvarno pozitivnih, koristi se za izražavanje proporcije pravilno identifikovanih abnormalnih belih krvnih zrnaca, dok specifičnost meri odnos ispravno klasifikovanih normalnih krvnih ćelija prema njihovom ukupnom broju.

Ukupna tačnost se meri kao odnos ispravno klasifikovanih ćelija prema ukupnom broju instanci:

$$Misclassification = FP + FN \quad (85)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (86)$$

U ovom radu, vrednosti dobijene jednačinama (83)–(86) se množe sa 100 tako da predstavljaju procenat ispravno klasifikovanih instanci.

Da bismo testirali naš predloženi metod i uporedili sa drugim metodama iz literature, eksperimente smo organizovali kao u [59]. Koristili smo standardnu bazu mikroskopskih slika krvnih zrnaca ALL-IDB [51]. U ovom istraživanju smo koristili ALL-IDB2 skup podataka gde smo za treniranje mašine potpornih vektora koristili po 50 slika normalnih ćelija i ćelija leukemija. Konstruisani SVM model je testiran na ostatku skupa, što je 66 ćelija leukemije i 76 normalnih ćelija.

Predloženi metod je upoređen sa metodom koja je predložena u [59]. U tom radu je predložena metoda zasnovana na karakteristikama oblika i DCT koeficijentima. Prvi korak te metode bila je redukcija šuma pomoću Weiner filtra zajedno sa poboljšanjem kontrasta. Drugi korak je bio proces segmentacije metodom razvođe (engl. watershed). DCT koeficijenti su izračunati za svaku izdvojenu ćeliju i SVM je korišćen za njihovu klasifikaciju. Predloženi metod je upoređen sa naivni Bajesov klasifikatorom (NB), k-najbližih suseda (KNN) i neuronskom mrežom sa povratnom spregom (engl. back propagation neural network, BPNN). Ove rezultate smo uključili u ovom istraživanju.

U poređenju sa metodom predloženom u [59], naša metoda koristi manje karakteristika kao ulazni vektor za klasifikator. Druga razlika je što nismo uključili nikakvo poboljšanje slike pre izdvajanja krvnih zrnaca. Sve ovo čini naš predloženi metod jednostavnijim od metode predložene u [59].

Poređenje rezultata prikazanih u [59] i rezultata dobijenih predloženom BBFWA metodom prikazana je u tabeli 19. Rezultati metode predložene u [59] su prikazani u koloni *DCT*. Bolji rezultati su podebljani.

Tabela 19: Poređenje rezultata iz rada [59] i predložene BBFWA metode

	NB	KNN	BPNN	DCT	SVM
Sensitivity	88.70	98.38	80.64	84.67	94.21
Specificity	75.38	69.23	37.67	94.61	89.37
Accuracy	81.66	83.46	58.70	89.76	91.84

Kao što se vidi, naša predložena BBFWA metoda postigla je veću tačnost u odnosu na sve četiri metode predstavljene u [59]. S obzirom na to da u ovom istraživanju nismo uključili poboljšanje slike u koraku predprocesiranja i da je broj karakteristika relativno mali u odnosu na druge metode, može se pretpostaviti da se

predloženi metod može još više poboljšati i još uvek biti manje ili jednako složen od metoda prikazanih u [59].


Iako je preciznost predložene metode veća u odnosu na metodu predloženu u [59] (91,84% u odnosu na 89,76%), osetljivost i specifičnost pojedinačno nisu bolji u odnosu na druge metode. Najbolja osetljivost (ispravno prepoznatih ćelija leukemija) dobijena je karakteristikama koje su predložene u [59] kada se koristi KNN kao klasifikator, 98,38%, dok je sa našim predloženim algoritmom 94,21%. Problem sa KNN metodom je da se brojne zdrave krvne ćelije ne prepoznaju ispravno. Može se zaključiti da KNN metoda u većini slučajeva klasifikuje ćelije kao ćelije leukemije što dovodi do visoke vrednosti mere osetljivosti, ali prilično niske specifičnosti.

U slučaju specifičnosti, najveća vrednost je postignuta DCT metodom predloženom u [59] 94%, dok je naš predloženi algoritam postigao specifičnost od 89,34%. S obzirom na to da je osetljivost postignuta metodom koja je predstavljena u [59] bila niska, ukupna tačnost je bila gora od tačnosti dobijene predloženom BBFWA metodom. Najgori rezultati postignuti su kada se koriste neuronske mreže sa povratno spregom: osetljivost je bila 80,64%, dok je specifičnost bila samo 37,67%. Ukupna tačnost bila je 58,70%. Neuronske mreže imaju mnogo parametara koje treba podesiti, a kvalitet klasifikacije zavisi od njih. Upotreba neodgovarajućih parametara može dovesti do loših rezultata kao u ovom slučaju.

Rano otkrivanje bilo koje bolesti je veoma važno i ključno za uspešan oporavak. Leukemija je jedno od oboljenja koja se mogu detektovati iz medicinskih digitalnih slika. U ovom istraživanju predložena je metoda koja se zasniva na karakteristikama oblika, boje i teksture za otkrivanje ćelija leukemije na mikroskopskim slikama krvi sa ciljem da se otkrije akutna limfoblastična leukemija. Koristili smo uniformni lokalni binarni uzorak kao deskriptor teksture, dok je oblik svake ćelije opisan odnosom površina citoplazma i jezgra i odnosom površina jezgra prema ćeliji, perimetru i oblasti. Za klasifikaciju belih krvnih zrnaca koristili smo mašinu potpornih vektora sa parametrima koji su određeni algoritmom vatrometa. Na osnovu rezultata komparativne analize može se zaključiti da je predloženi metod pogodan za ALL detekciju na mikroskopskim slikama. U budućem radu može se prilagoditi predloženi metod za detekciju drugih tipova leukemije, testirati sa drugim skupom karakteristika i uključiti poboljšanje slike u korak predprocesiranja.


8.6 Detekcija bolesti pluća na CT slikama

Još jedna od interesantnih i aktivnih istraživačkih tema u polju obrade medicinskih digitalnih slika je detekcija bolesti pluća sa CT slika, posebno hronične opstruktivne bolesti pluća (engl. chronic obstructive pulmonary disease, COPD) kao što je emfizema. Uobičajena metoda za rano otkrivanje COPD je korišćenjem CT snimanja koje omogućava detekciju emfizema. Primer slike CT pluća je prikazan na slici 45.



Slika 45: *CT pluća*


Emfizem je hronična i progresivna bolest pluća koja izaziva kratak dah i uvećanje disajnih puteva. Mogu se razlikovati tri vrste emfizema: centrilobularni emfizem (CLE), paraseptalni emfizem (PSE) i panlobularni emfizem (PLE). Primeri normalnog tkiva (NT), CLE i PSE su prikazani na slici 2 46.



(a) NT - normalno tkivo



(b) CLE - centrilobularni emfizem



(c) PSE - paraseptalni emfizem

Slika 46: *Primer zdravog tkiva i različitih emfizema*

U poslednjih nekoliko godina predložene su različite metode za detekciju i klasifikaciju emfizema. Neki od poznatih klasifikatora su korišćeni za obeležavanje tipova tkiva kao što je k najbližih suseda (KNN) [37], veštačke neuralne mreže [6], konvolucione neuralne mreže [73], [3], itd. Pored izbora metode klasifikacije, izbor

karakteristika je veoma važan deo računarski vođenih dijagnostičkih sistema (engl. computer aided diagnostic systems, CAD) za klasifikaciju emfizema.

U ovom istraživanju smo predložili metodu otkrivanja i klasifikacije emfizema. Za klasifikaciju su korišćene mašine potpornih vektora (SVM) dok su tkiva pluća na CT slikama opisana uniformnim lokalnim binarnim uzorkom (LBP) i karakteristikama histograma intenziteta. Korišćeno je samo šest različitih karakteristika uniformnog lokalnog binarnog uzorka i histograma inteziteta kao ulazni vektor za klasifikator, odnosno za mašinu potpornih vektora. Vektor karakteristika je značajno smanjen u poređenju sa drugim metodama iz literature, dok je preciznost klasifikacije povećana. Rezultati ovog istraživanja su opisani i objavljeni u [89].

Predloženi metod se sastoji iz dva glavna dela, izdvajanja karakteristika i klasifikacije. U prošlosti je dokazano da deskriptori teksture mogu dobro razlikovati različite tipove emfizema [74], [102]. Odabir odgovarajućih karakteristika su obavezne za visoku preciznost klasifikacije, ali preciznost takođe zavisi i od kvaliteta klasifikatora, pa je ovom istraživanju korišćenja mašina potpornih vektora optimizovana algoritmom svica.


Kao karakteristike koje se koriste kao ulazni vektor klasifikatora predložili smo šest zajedničkih metrika. Za svaki histogram, histograma LBP-a i histogram intenziteta, su izračunate srednja vrednost (μ), standardna devijacija (σ), asimetrija, kurtosis, energija i entropija i korišćeni su kao ulazni vektor. Koristeći ove metrike dobija se 12-dimenzionalni vektor karakteristika (6 vrednosti za LBP histogram i 6 vrednosti za histogram inteziteta).

Parametri za FA korišćeni u ovom istraživanju su empirijski postavljeni na sledeći način:

- $\alpha = 0.2$, $\gamma = 0.23$ i $\beta_0 = 1$,
- veličina populacije je bila 50,
- maksimalni broj iteracija je 30
- ako se tačnost nije poboljšala u 10 uzastopnih iteracija , algoritam se zaustavlja.

Za eksperimente smo koristili standardnu javnu bazu CT slika emfizeme [74] dostupnu na internet stranici image.diku.dk/emphysema_database/. Baza sadrži

168 regiona od interesa (ROI) veličine 61×61 , debljine preseka 1,25 mm i rezolucije u ravnini od $0,78 \text{ mm} \times 0,78 \text{ mm}$. Svakom regionu je određena labela od strane eksperta. Postoje tri različite vrste ROI u bazi: normalno tkivo (NT), centrilobularni emfizem (CLE) i paraseptalni emfizem (PSE). Primeri regiona iz baze prikazani su na slici 47.



Slika 47: Primer uzoraka iz korišćene baze: normalno tkivo i emfizme

Prvi deo metode je treniranje modela SVM za klasifikaciju regiona iz baza. Pošto korišćena baza ima mali broj uzoraka, uobičajena praksa je da se model trenira nad celom bazom (isto je urađeno i u radovima sa kojim se poredimo, [74] i [102]). U ovom istraživanju smo koristili regione veličine 31×31 što znači da za svaki uzorak iz baze generišemo 961 preklapajući region. Zahvaljući tome moguće je razdvojiti trening i test skup. SVM model je treniran na po 1000 nasumično odabranih blokova iz svake klase (ukupno 3000). Dobijeni model je testiran na preostalih 1500 regiona.

Model najveće tačnosti, 98.18%, se dobio za $C = 2^{18.23}$ i $\gamma = 2^{-12.36}$. U tabeli 20 je prikazana matrica konfuzije za ovu klasifikaciju (rezultati su izraženi u procentima).

	NT	CLE	PSE
NT	100	0	0
CLE	0	100	0
PSE	0	5.47	94.53

Tabela 20: Matrica konfuzije za klasifikaciju uzoraka iz korišćene baze predloženom metodom (tačnosti prikazane u %)

Kako bi testirali kvalitet predložene metode dobijene rezultate smo uporedili sa dve metode iz literature. Prvi metod je predložen u radu [74]. Predloženo je korišćenje različitih rotaciono invarijantnih LBP deskriptora zajedno sa histogramom inteziteta. Za klasifikaciju je korišćen KNN. Ulazni vektor za klasifikaciju je kombinovao cele

LBP histograme i histogram inteziteta. Drugi algoritam koji je korišćen za poređenje je predložen u [102]. U tom radu tekstura je opisana retkom dekompozicijom tekston rečnika. Dekompoziciju su dodatno razredili dodavanjem određenih ograničenja unutar rečnika.

Metoda predložena u [74] postigla je tačnost klasifikacije 95.24%. Naš predloženi algoritam je postigao tačnost 98.18% za klasifikaciju regiona CT slika pluća. Najveća greška klasifikacije u [74] je napravljena za klasu NT, gde je 6.88% uzoraka prepoznato kao instance klase PSE. Sa druge strane, naš predloženi algoritam je najmanju tačnost postigao za klasu PSE i iznosila je 94.53%. Instance klase PSE su klasifikovane kao CLE u 5.47% slučajeva. Maksimalne tačnosti, 100%, su postignute predloženom metodom prilikom klasifikacije instanci klasa NT i CLE. U [102] najveća postignuta tačnost je bila 93,9%, dok su ostale metode dostigle tačnosti od 92,1%, 91,8%, 92,4% i 91,7%. Svi prijavljeni rezultati u [102] bili su niži od tačnosti predložene metode koja je dostigla 98,18%. Rezultati poređenja prikazani su u tabeli 21.

	THM	LBP-kNN	FA-SVM
NT	-	93.22	100
CLE	-	98.00	100
PSE	-	93.91	94.53
global acc.	93.9	95.24	98.18

Tabela 21: *Poređenje rezultata predloženog algoritma sa metodama predloženim u [74] i [102]*

Predloženi metod je takođe postigao bolje rezultate klasifikacije u odnosu na metod iz rada [62] gde je ulazni vektor za klasifikaciju pomoću linearnog SVM sadržao kompletne zajedničke histograme tri različite varijante LBP kao i histogram intenziteta. Tačnosti modela sa različitim ulaznim vektorima su bile 81,36%, 82,99% i 83,29%, dok je tačnost predložene FA-SVM metode bila 98,18%.

U ovom istraživanju predložena je metoda za klasifikaciju tkiva pluća. Različiti tipovi tkiva pluća opisana su uniformnim lokalnim binarnim uzorkom. Pored karakteristika teksture, korišćene su karakteristike intenziteta. U ovom istraživanju ulazni vektor za klasifikator je smanjen u poređenju sa drugim metodama iz literature zato što su korišćene karakteristike histograma kao što su srednja vrednost, standardna devijacija, asimetrija, kurtosis, energija i entropija, umesto kompletnog histograma. U poređenju sa drugim metodama iz literature, predloženi metod je

postigao veću tačnost klasifikacije regiona od interesa koji su dati u standardnom skupu CT slika pluća. U daljem radu može se uključiti izbor karakteristika (engl. features extraction).

9 Zaključak

U ovom radu predloženo je unapređenje obrade medicinskih digitalnih slika pomoću algoritama inteligencije rojeva. Oblast procesiranja digitalnih slika, posebno medicinskih slika, aktivna je istraživačka oblast. Sa druge strana, oblast proučavanja algoritama inteligencije rojeva za rešavanje problema optimizacije već decenijama privlači pažnju naučnika iz različitih oblasti. Može se reći da su u ovom radu obuhvaćene dve aktivne istraživačke oblasti.

Prvi razmatrani problem bio je registracija slika retina rigidnim transformacijama. Za ovaj težak optimizacioni problem prilagođen je novi algoritam vatrometa i testiran na slikama retina iz standardnih skupova koji se koriste u literaturi. Predložena metoda upoređena je sa 6 drugih tehnika iz literature i postigla je bolje rezultate. Dodatno, predložena metoda je uspešno izvršila registraciju slika i za velika pomeranja.

Drugi razmatrani problem je određivanje optimalnih trešhold vrednosti za segmentaciju MRI slika mozga Kapurovom metodom i Otsuovom metodom. Kapurov i Otsuov metod su optimizovani prilagođenim algoritmom inteligencije rojeva, algoritmom slepog miša. Kvalitet predloženog algoritma testiran je na standardnim test slikama. Rezultati su upoređeni sa rezultatima postignutim sa četiri različita algoritma za optimizaciju iz literature: genetski algoritam, optimizacija rojem čestica, adaptivna bakterijska ishrana i genetski algoritam sa realnim kodiranjem rešenja. Predloženi algoritam postigao je bolje rezultate u odnosu na pomenute algoritme i pri tome je imao najmanju standardnu devijaciju prilikom višestrukog pokretanja metode.

Treći razmatrani problem bio je kompresija medicinskih slika optimizovanom kvantizacionom tabelom. Najnovija verzija algoritma vatrometa, BBFWA, prilagođena je za rešavanje ovog problema optimizacije i tom prilikom su se koristile dve različite fitnes funkcije. Kvantizaciona tabela je generisana tako da se zahtevao određeni nivo kompresije a da se pri tome maksimizuje kvalitet dekompresovane slike u smislu dve mere sličnosti, srednje kvadratne greške i normalizovane unakrsne korelacije. Predložena metoda bazirana na algoritmu vatrometa značajno je poboljšala kvalitet kompresije u odnosu na standardni JPEG algoritam.

Predložene su i tri metode detekcije anomalija na različitim slikama, CT, CE i mikroskopskim slikama. U sva tri slučaja selektovale su se karakteristike povezane sa razmatranom anomalijom. Selektovane karakteristike kao što su parametri LBP histograma koristile su se kao ulazni vektor za SVM. Optimizacija parametara SVM izvršena je algoritmima inteligencije rojeva. U sva tri slučaja predložene su metode postigle bolje rezultate, veću tačnost klasifikacije u odnosu na savremene metode iz literature.

Na osnovu rezultata izloženih u ovoj disertaciji, može se zaključiti da:

- Problemi obrade medicinskih digitalnih slika mogu biti teški optimizacioni problemi, kontinualni (primer registracija slika retine), diskretni (primer: određivanje trešhold vrednosti), sa ili bez ograničenja (biranje elemenata kvantizacione tabele je primer problema optimizacije sa ograničenjem)
- Algoritmi inteligencije rojeva se mogu lakše ili teže modifikovati za rešavanje problema optimizacije obrade medicinskih digitalnih slika i pronalaze optimalna ili skoro optimalna rešenja
- Na osnovu prethodnog tvrđenja, potvrđeno je da se algoritmi inteligencije rojeva mogu uspešno primeniti na teške optimizacione probleme koji se pojavljuju prilikom obrade medicinskih digitalnih slika.

10 Literatura

- [1] Alam, L., Dhar, P.K., Hasan, M.A.R., Bhuyan, M.G.S., Daiyan, G.M.: An improved JPEG image compression algorithm by modifying luminance quantization table. *International Journal of Computer Science and Network Security (IJCSNS)* 17(1), 200 (2017)
- [2] Alihodzic, A., Tuba, M.: Improved bat algorithm applied to multilevel image thresholding. *The Scientific World Journal*, special issue Computational Intelligence and Metaheuristic Algorithms with Applications, 2014(Article ID 176718), 16 (2014)
- [3] Anthimopoulos, M., Christodoulidis, S., Ebner, L., Christe, A., Mougiakakou, S.: Lung pattern classification for interstitial lung diseases using a deep convolutional neural network. *IEEE transactions on medical imaging* 35(5), 1207–1216 (2016)
- [4] Back, T.: *Evolutionary algorithms in theory and practice: evolution strategies, evolutionary programming, genetic algorithms*. Oxford university press (1996)
- [5] Barbedo, J.G.A., Koenigkan, L.V., Santos, T.T.: Identifying multiple plant diseases using digital image processing. *Biosystems engineering* 147, 104–116 (2016)
- [6] Beheshti, Z., Shamsuddin, S.M.H., Beheshti, E., Yuhaniz, S.S.: Enhancement of artificial neural network learning using centripetal accelerated particle swarm optimization for medical diseases diagnosis. *Soft Computing* 18(11), 2253–2270 (2014)
- [7] Bloomer, P., Bloomer, D.: X-ray atlas, http://www.glowm.com/atlas_page/atlasid/rc007.html
- [8] Boss, A., Bisdas, S., Kolb, A., Hofmann, M., Ernemann, U., Claussen, C.D., Pfannenberger, C., Pichler, B.J., Reimold, M., Stegger, L.: Hybrid PET/MRI of intracranial masses: initial experiences and comparison to PET/CT. *Journal of Nuclear Medicine* 51(8), 1198–1205 (2010)

- [9] Bunting, P., Labrosse, F., Lucas, R.: A multi-resolution area-based technique for automatic multi-modal image registration. *Image and Vision Computing* 28(8), 1203–1219 (2010)
- [10] Burnett, J.D., Wing, M.G.: A low-cost near-infrared digital camera for fire detection and monitoring. *International Journal of Remote Sensing* 39(3), 741–753 (2018)
- [11] Cai, J., Okamoto, M., Atieno, J., Sutton, T., Li, Y., Miklavcic, S.J.: Quantifying the onset and progression of plant senescence by color image analysis for high throughput applications. *PloS one* 11(6), e0157102 (2016)
- [12] Cao, Z., Shi, Y., Rong, X., Liu, B., Du, Z., Yang, B.: Random Grouping Brain Storm Optimization Algorithm with a New Dynamically Changing Step Size, pp. 357–364. Springer International Publishing, Cham (2015)
- [13] Chen, J., Tian, J., Lee, N., Zheng, J., Smith, R.T., Laine, A.F.: A partial intensity invariant feature descriptor for multimodal retinal image registration. *IEEE Transactions on Biomedical Engineering* 57(7), 1707–1718 (2010)
- [14] Chen, J., Wang, J., Cheng, S., Shi, Y.: Brain Storm Optimization with Agglomerative Hierarchical Clustering Analysis, pp. 115–122. Springer International Publishing, Cham (2016)
- [15] Coupe, P., Eskildsen, S.F., Manjon, J.V., Fonov, V.S., Collins, D.L.: Simultaneous segmentation and grading of anatomical structures for patient’s classification: Application to Alzheimer’s disease. *NeuroImage* 59(4), 3736–3747 (2012)
- [16] Dataset: Medical Imaging of the Abdomen, Department of Neurobiology and Developmental Sciences, University of Arkansas for Medical Sciences, <http://anatomy.uams.edu/xraythoraxabdomen.html>
- [17] Dataset: Ultrasound images, The American Institute of Ultrasound in Medicine (2019), <https://www.aium.org/patients/gallery.aspx>
- [18] Debayle, J., Presles, B.: Rigid image registration by general adaptive neighborhood matching. *Pattern Recognition* 55, 45–57 (2016)

- [19] Deeba, F.: Bleeding images and corresponding ground truth of CE images (2016), <https://sites.google.com/site/farahdeeba073/Research/resources>
- [20] Deeba, F., Bui, F.M., Wahid, K.A.: Automated growcut for segmentation of endoscopic images. In: 2016 International Joint Conference on Neural Networks (IJCNN). pp. 4650–4657. IEEE (2016)
- [21] Dey, N., Ashour, A.S., Ashour, A., Singh, A.: Digital analysis of microscopic images in medicine. *Journal of Advanced Microscopy Research* 10, 1–13 (06 2015)
- [22] Dice, L.R.: Measures of the amount of ecologic association between species. *Ecology* 26(3), 297–302 (1945)
- [23] Dorigo, M.: Ant Colony Optimization for vehicle routing problem. Ph.D. thesis, PhD thesis, Politecnico di Milano, Milan, Italy (1992)
- [24] Dorigo, M., Gambardella, L.M.: Ant colonies for the travelling salesman problem. *Biosystems* 43(2), 73–81 (1997)
- [25] Dougherty, G.: Digital image processing for medical applications. Cambridge University Press (2009), p. 485
- [26] Dougherty, G.: Medical image processing: techniques and applications. Science and Business Media, Springer (2011), p. 388
- [27] Dua, R.L., Gupta, N.: Fast color image quantization based on bacterial foraging optimization. In: Fourth International Conference on Advances in Recent Technologies in Communication and Computing (ARTCom). pp. 100–102 (2012)
- [28] Fister Jr., I., Fister, D., Yang, X.S.: A hybrid bat algorithm. *Elektrotehniski Vestnik/Electrotechnical Review* 80(1-2), 1–7 (2013)
- [29] Gandomi, A.H., Yang, X.S., Alavi, A.H., Talatahari, S.: Bat algorithm for constrained optimization tasks. *Neural Computing and Applications* 22(6), 1239–1255 (2012)

- [30] Gharabaghi, S., Daneshvar, S., Sedaaghi, M.H.: Retinal image registration using geometrical features. *Journal of digital imaging* 26(2), 248–258 (2013)
- [31] Glover, F.: Future paths for integer programming and links to artificial intelligence. *Computers & operations research* 13(5), 533–549 (1986)
- [32] Gonçalves, H., Gonçalves, J.A., Corte-Real, L.: Hairis: A method for automatic image registration through histogram-based image segmentation. *IEEE transactions on image processing* 20(3), 776–789 (2011)
- [33] Gonzalez, R.C., Woods, R.E.: *Digital image processing*, 3rd Edition. Pearson, Prentice Hall (2008), p. 954
- [34] Gupta, M., Garg, A.K.: Analysis of image compression algorithm using DCT. *International Journal of Engineering Research and Applications (IJERA)* 2(1), 515–521 (2012)
- [35] Ha, W., Gowda, P.H., Howell, T.A.: A review of potential image fusion methods for remote sensing-based irrigation management: Part ii. *Irrigation Science* 31(4), 851–869 (2013)
- [36] Holland, J.: An efficient genetic algorithm for the traveling salesman problem. *European Journal of Operational Research* 145, 606–617 (1975)
- [37] Ibrahim, M., Mukundan, R.: Multi-fractal techniques for emphysema classification in lung tissue images. *International Conference on Environment, Chemistry and Biology* 78, 115–119 (2014)
- [38] Ilovar, M., Šajn, L.: Analysis of radiograph and detection of cardiomegaly. In: *34th International Convention MIPRO*. pp. 859–863. IEEE (2011)
- [39] Iqbal, F.: Detection of salt affected soil in rice-wheat area using satellite image. *African Journal of Agricultural Research* 6(21), 4973–4982 (2011)
- [40] Jafari-Khouzani, K., Elisevich, K.V., Patel, S., Soltanian-Zadeh, H.: Dataset of magnetic resonance images of nonepileptic subjects and temporal lobe epilepsy patients for validation of hippocampal segmentation techniques. *Neuroinformatics* 9(4), 335–346 (2011)

- [41] Johnsen, G., Volent, Z., Dierssen, H., Pettersen, R., Van Ardelan, M., Søreide, F., Fearn, P., Ludvigsen, M., Moline, M.: Underwater hyperspectral imagery to create biogeochemical maps of seafloor properties. In: Subsea optics and imaging, pp. 508–540e. Elsevier (2013)
- [42] Johnson, K.A., Becker, J.A.: The whole brain atlas [Online], <http://www.med.harvard.edu/AANLIB/>
- [43] Ju, J., Loew, M., Ku, B., Ko, H.: Hybrid retinal image registration using mutual information and salient features. *IEICE Transactions on Information and Systems* 99(6), 1729–1732 (2016)
- [44] Kapur, J., Sahoo, P., Wong, A.: A new method for gray-level picture thresholding using the entropy of the histogram. *Computer Vision, Graphics, and Image Processing* 29(3), 273–285 (1985)
- [45] Kempton, M.J., Underwood, T.S., Brunton, S., Stylios, F., Schmechtig, A., Ettinger, U., Smith, M.S., Lovestone, S., Crum, W.R., Frangou, S., Williams, S.C., Simmons, A.: A comprehensive testing protocol for MRI neuroanatomical segmentation techniques: Evaluation of a novel lateral ventricle segmentation method. *NeuroImage* 58(4), 1051–1059 (2011)
- [46] Kennedy, J., Eberhart, R.: Particle swarm optimization. In: *Proceedings of the IEEE International Conference on Neural Networks*. vol. 4, pp. 1942–1948 vol.4 (Nov 1995)
- [47] Khan, M.K., Nystrom, I.: A modified particle swarm optimization applied in image registration. In: *20th International Conference on Pattern Recognition*. pp. 2302–2305. IEEE (2010)
- [48] Koza, J.R., Koza, J.R.: *Genetic programming: on the programming of computers by means of natural selection*, vol. 1. MIT press (1992)
- [49] Kumar, B.V., Karpagam, M.: Differential evolution versus genetic algorithm in optimising the quantisation table for JPEG baseline algorithm. *International Journal of Advanced Intelligence Paradigms* 7(2), 111–135 (2015)

- [50] Kybic, J.: Bootstrap resampling for image registration uncertainty estimation without ground truth. *IEEE Transactions on Image Processing* 19(1), 64–73 (2010)
- [51] Labati, R.D., Piuri, V., Scotti, F.: All-IDB: The acute lymphoblastic leukemia image database for image processing. In: 18th IEEE international conference on Image processing (ICIP). pp. 2045–2048. IEEE (2011)
- [52] Lazzerini, B., Marcelloni, F., Vecchio, M.: A multi-objective evolutionary approach to image quality/compression trade-off in JPEG baseline algorithm. *Applied Soft Computing* 10(2), 548–561 (2010)
- [53] Li, J., Zheng, S., Tan, Y.: The effect of information utilization: Introducing a novel guiding spark in the fireworks algorithm. *IEEE Transactions on Evolutionary Computation* 21(1), 153–166 (Feb 2017)
- [54] Li, J., Tan, Y.: The bare bones fireworks algorithm: A minimalist global optimizer. *Applied Soft Computing* 62, 454–462 (2018)
- [55] Lu, H., Zhang, Y., Li, Y., Zhou, Q., Tadoh, R., Uemura, T., Kim, H., Serikawa, S.: Depth map reconstruction for underwater kinect camera using inpainting and local image mode filtering. *IEEE Access* 5, 7115–7122 (2017)
- [56] Ma, H., Zhang, Q.: Research on cultural-based multi-objective particle swarm optimization in image compression quality assessment. *Optik-International Journal for Light and Electron Optics* 124(10), 957–961 (2013)
- [57] Manikandan, S., Ramar, K., Iruthayarajan, M.W., Srinivasagan, K.: Multilevel thresholding for segmentation of medical brain images using real coded genetic algorithm. *Measurement* 47, 558–568 (2014)
- [58] Martini, R., Reinelt, G.: The Linear Ordering Problem Exact and Heuristic Methods in Combinatorial Optimization. *Applied Mathematical Sciences*, Springer-Verlag Berlin Heidelberg (2011)
- [59] Mishra, S., Sharma, L., Majhi, B., Sa, P.K.: Microscopic image classification using DCT for the detection of acute lymphoblastic leukemia (ALL). In: Proce-

- edings of International Conference on Computer Vision and Image Processing. pp. 171–180. Springer (2017)
- [60] Nakamura, R., Pereira, L., Costa, K., Rodrigues, D., Papa, J., Yang, X.S.: BBA: A binary bat algorithm for feature selection. In: 25th Conference on Graphics, Patterns and Images. pp. 291–297 (2012)
 - [61] Nejati, M., Pourghassem, H.: Multiresolution image registration in digital X-ray angiography with intensity variation modeling. *Journal of medical systems* 38(2), 10 (2014)
 - [62] Nishio, M., Koyama, H., Ohno, Y., Sugimura, K.: Classification of emphysema subtypes: Comparative assessment of local binary patterns and related texture features. *Advances in Computed Tomography* 4(03), 47–55 (2015)
 - [63] Otsu, N.: A threshold selection method from gray-level histograms. *Automatica* 11(285-296), 23–27 (1975)
 - [64] Perea-Moreno, A.J., Aguilera-Ureña, M.J., Larriva, M.D., Manzano-Agugliaro, F., et al.: Assessment of the potential of UAV video image analysis for planning irrigation needs of golf courses. *Water* 8(12), 584 (2016)
 - [65] Rana, S.: A review of medical image enhancement techniques for image processing. *International Journal of Current Engineering and Technology* 5, 1282–1286 (2011)
 - [66] Reel, P.S., Dooley, L.S., Wong, K.C.P., Börner, A.: Robust retinal image registration using expectation maximisation with mutual information. In: IEEE International Conference on Acoustics, Speech and Signal Processing. pp. 1118–1122. IEEE (2013)
 - [67] Rooks, V., Chung, E.M.: Esophageal foreign body imaging, <https://emedicine.medscape.com/article/408752-overview>
 - [68] Sathya, P., Kayalvizhi, R.: Optimal segmentation of brain MRI based on adaptive bacterial foraging algorithm. *Neurocomputing* 74(14-15), 2299–2313 (2011)

- [69] Saxena, S., Singh, R.K.: A survey of recent and classical image registration methods. *International journal of signal processing, image processing and pattern recognition* 7(4), 167–176 (2014)
- [70] Schoening, T., Bergmann, M., Ontrup, J., Taylor, J., Dannheim, J., Gutt, J., Purser, A., Nattkemper, T.W.: Semi-automated image analysis for the assessment of megafaunal densities at the arctic deep-sea observatory hausgarten. *PloS one* 7(6), e38179 (2012)
- [71] Shi, Y.: Brain storm optimization algorithm. In: *Advances in Swarm Intelligence*, LNCS. vol. 6728, pp. 303–309. Springer Berlin Heidelberg (2011)
- [72] Shiee, N., Bazin, P.L., Ozturk, A., Reich, D.S., Calabresi, P.A., Pham, D.L.: A topology-preserving approach to the segmentation of brain images with multiple sclerosis lesions. *NeuroImage* 49(2), 1524–1535 (2010)
- [73] Shouno, H., Suzuki, S., Kido, S.: A transfer learning method with deep convolutional neural network for diffuse lung disease classification. In: *International Conference on Neural Information Processing*. pp. 199–207. Springer (2015)
- [74] Sorensen, L., Shaker, S.B., de Bruijne, M.: Quantitative analysis of pulmonary emphysema using local binary patterns. *IEEE Transactions on Medical Imaging* 29(2), 559–569 (2010)
- [75] Staal, J., Abràmoff, M.D., Niemeijer, M., Viergever, M.A., Van Ginneken, B.: Ridge-based vessel segmentation in color images of the retina. *IEEE transactions on medical imaging* 23(4), 501–509 (2004)
- [76] Stanton, A.: Wilhelm Conrad Röntgen on a new kind of rays: translation of a paper read before the Würzburg physical and medical society, 1895. *Nature* 53(1369), 274–276 (1896)
- [77] Storn, R., Price, K.: Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. *Journal of global optimization* 11(4), 341–359 (1997)

- [78] Storn, R., Price, K.: Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. *Journal of global optimization* 11(4), 341–359 (1997)
- [79] Suckling J, P.: The mammographic image analysis society digital mammogram database. *Digital Mammo* pp. 375–386 (1994)
- [80] Sundar, R., Hebbar, S., Golla, V.: Implementing intelligent traffic control system for congestion control, ambulance clearance, and stolen vehicle detection. *IEEE Sensors Journal* 15(2), 1109–1113 (2015)
- [81] Talbi, E.G.: *Metaheuristics: from design to implementation*, vol. 74. John Wiley & Sons (2009), p. 625
- [82] Tan, Y., Zhu, Y.: Fireworks algorithm for optimization. In: *Advances in Swarm Intelligence, Part I*. pp. 355–364. Springer, Berlin Heidelberg (2010)
- [83] Tewari, V., Arudra, A.K., Kumar, S.P., Pandey, V., Chandel, N.S.: Estimation of plant nitrogen content using digital image processing. *Agricultural Engineering International: CIGR Journal* 15(2), 78–86 (2013)
- [84] Thai, T.H., Cogranne, R., Retraint, F., et al.: JPEG quantization step estimation and its applications to digital image forensics. *IEEE Transactions on Information Forensics and Security* 12(1), 123–133 (2017)
- [85] Tuba, E., Capor Hrosik, R., Zivkovic, D., Tuba, M.: Multilevel thresholding for segmentation of brain magnetic resonance images using bat algorithm. submitted for publication: *Studies in Informatics and Control* pp. 1–14
- [86] Tuba, E., Jovanovic, R., Beko, M., Tallón-Ballesteros, A.J., Tuba, M.: Bare bones fireworks algorithm for medical image compression. In: *LNCS: International Conference on Intelligent Data Engineering and Automated Learning*. pp. 262–270. Springer (2018)
- [87] Tuba, E., Tuba, M., Dolicanin, E.: Adjusted fireworks algorithm applied to retinal image registration. *Studies in Informatics and Control* 26(1), 33–42 (2017)

- [88] Tuba, E., Tuba, M., Jovanovic, R.: An algorithm for automated segmentation for bleeding detection in endoscopic images. In: International Joint Conference on Neural Networks (IJCNN). pp. 4579–4586. IEEE (2017)
- [89] Tuba, E., Tuba, M., Simian, D.: Support vector machine optimized by firefly algorithm for emphysema classification in lung tissue CT images. ACM Computer Science Research Notes 2702 (2017)
- [90] Tuba, E., Tuba, M., Simian, D., Jovanovic, R.: JPEG quantization table optimization by guided fireworks algorithm. In: Combinatorial Image Analysis, Lecture Notes in Computer Science, vol. 10256, pp. 294–307. Springer (2017)
- [91] Tuba, M., Alihodzic, A., Bacanin, N.: Cuckoo search and bat algorithm applied to training feed-forward neural networks. In: Yang, X.S. (ed.) Recent Advances in Swarm Intelligence and Evolutionary Computation, Studies in Computational Intelligence, vol. 585, pp. 139–162. Springer International Publishing (2015)
- [92] Tuba, M., Bacanin, N.: JPEG quantization tables selection by the firefly algorithm. In: International Conference on Multimedia Computing and Systems (ICMCS). pp. 153–158. IEEE (2014)
- [93] Tuba, M., Bacanin, N.: Hybridized bat algorithm for multi-objective radio frequency identification (RFID) network planning. In: IEEE Congress on Evolutionary Computation (CEC), 2015. pp. 499–506 (May 2015)
- [94] Umar, M.M., Silva, L.C.D., Bakar, M.S.A., Petra, M.I.: State of the art of smoke and fire detection using image processing. International Journal of Signal and Imaging Systems Engineering 10(1-2), 22–30 (2017)
- [95] Valsecchi, A., Damas, S., Santamaria, J.: Evolutionary intensity-based medical image registration: a review. Current Medical Imaging Reviews 9(4), 283–297 (2013)
- [96] Vidhya, K., Banu, A.B.: Density based traffic signal system. International Journal of Innovative Research in Science, Engineering and Technology 3(3), 2218–2222 (2014)

- [97] Viswajaa, S., Kumar, V., Karpagam, G.R.: A survey on nature inspired meta-heuristics algorithm in optimizing the quantization table for JPEG baseline algorithm. *International Advanced Research Journal in Science, Engineering and Technology* 2(4), 114–123 (2015)
- [98] Wang, G.G., Deb, S., Gao, X.Z., Coelho, L.D.S.: A new metaheuristic optimisation algorithm motivated by elephant herding behaviour. *International Journal of Bioinspired Computation* 8(6), 394–409 (2016)
- [99] Wang, G., Guo, L.: A novel hybrid bat algorithm with harmony search for global numerical optimization. *Journal of Applied Mathematics* 2013, 1–21 (2013)
- [100] Wang, K., Luo, J.: Detecting visually observable disease symptoms from faces. *EURASIP Journal on Bioinformatics and Systems Biology* 2016(1), 13 (2016)
- [101] Wikimedia: Classification of metaheuristics (2019), https://commons.wikimedia.org/wiki/File:Metaheuristics_classification.svg
- [102] Yang, J., Feng, X., Angelini, E.D., Laine, A.F.: Texton and sparse representation based texture classification of lung parenchyma in CT images. In: 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). pp. 1276–1279 (2016)
- [103] Yang, X.S.: Firefly algorithms for multimodal optimization. *Stochastic Algorithms: Foundations and Applications, Lecture Notes in Computer Science* 5792, 169–178 (2009)
- [104] Yang, X.S.: *Nature-Inspired Metaheuristic Algorithms: Second Edition*. Luni-ver Press (July 2010), p. 148
- [105] Yang, X.S.: A new metaheuristic bat-inspired algorithm. *Studies in Computational Intelligence* 284, 65–74 (2010)
- [106] Yang, X.S.: Bat algorithm for multi-objective optimisation. *International Journal of Bio Inspired Computation* 3(5), 267–274 (2011)

- [107] Yang, X.S., Gandomi, A.H.: Bat algorithm: a novel approach for global engineering optimization. *Engineering Computations* 29(5), 464–483 (2012)
- [108] Yang, X.S., Karamanoglu, M.: Swarm intelligence and bio-inspired computation: an overview. In: *Swarm Intelligence and Bio Inspired Computation*, pp. 3–23. Elsevier (2013)
- [109] Yudong, Z., Lenan, W.: Multi-resolution rigid image registration using bacterial multiple colony chemotaxis. *5th International Conference on Visual Information Engineering* pp. 528–532 (2008)
- [110] Zhang, J.W., Wang, G.G.: Image matching using a bat algorithm with mutation. *Applied Mechanics and Materials* 203(1), 88–93 (2012)
- [111] Zhang, Y., Wu, L.: Rigid image registration by psosqp algorithm. *Advances in Digital Multimedia* 1(1), 4–8 (2012)
- [112] Zheng, S., Janecek, A., Tan, Y.: Enhanced fireworks algorithm. In: *IEEE Congress on Evolutionary Computation (CEC)*. pp. 2069–2077 (June 2013)
- [113] Zhou, H., Schaefer, G., Sadka, A.H., Celebi, M.E.: Anisotropic mean shift based fuzzy c-means segmentation of dermoscopy images. *IEEE Journal of Selected Topics in Signal Processing* 3(1), 26–34 (2009)