BRZA SEGMENTACIJA SLIKE METODOM PROCJENE GUSTOĆE

Damir Krstinić

14. svibnja 2008.

Mentor: dr. sc. Ivan Slapničar, red. prof.

Komentor: dr. sc. Darko Stipaničev, red. prof.

Sadržaj

1	Uvo	od		17
2	Seg	Segmentacija slike		21
	2.1	Percep	ocija boje	22
		2.1.1	Reprezentacija boja	24
		2.1.2	Dijagram kromatičnosti	25
		2.1.3	Udaljenosti u prostoru boja	27
	2.2	Metod	le segmentacije	30
		2.2.1	Amplitudna segmentacija	31
		2.2.2	Grupiranje u vektorskom prostoru	32
		2.2.3	Particioniranje grafa	33
		2.2.4	Grupiranje analizom gustoće	34
		2.2.5	Segmentacija izrastanjem područja	35
		2.2.6	Segmentiranje dijeljenjem i stapanjem	35
		2.2.7	Segmentiranje otkrivanjem granica	36
		2.2.8	Neuralne mreže	38
		2.2.9	Fizikalne metode	38
3	Ada	optivna	a segmentacija slike mrežom diskretnih elemenata	39
-	3.1	3.1 Metode klasterirania temeliene na gustoći i rasterizaciji prostora		40
	3.2	Klaste	riranje procienom gustoće	42
		3.2.1	Estimacija gustoće jezgrom	43
		3.2.2	Optimalna pojasna propusnost h	45
		3.2.3	Varijabilna pojasna propusnost $h = h(x)$	49
		3.2.4	Žarišta funkcije gustoće i gravitirajuća područja	50
		3.2.5	Osjetljivost na šum	52
	3.3	Klaste	riranje diskretizacijom prostora	55
	3.4	Segme	entacija slike diskretizacijom prostora	57
		3.4.1	Prostorna domena i domena boja	58
		3.4.2	Diskretna aproksimacija gustoće u domeni boja	59
		3.4.3	Otkrivanje žarišta i gravitirajućih područja	64
		3/1/		07
		0.4.4	Preslikavanje u prostornu domenu slike	67
		3.4.5	Preslikavanje u prostornu domenu slike	67 68

	3.5	Analiza složenosti algoritma segmentacije	69
	3.6	Upravljački parametri algoritma segmentacije	70
		3.6.1 Faktor proporcionalnosti ρ	70
		3.6.2 Pojasna propusnost $h_r^{(0)}$	72
		3.6.3 Relativna razina šuma ε	72
		3.6.4 Minimalna veličina segmenta ϑ	73
		3.6.5 Dodatni upravljački parametri	73
4	Obj	ektivna evaluacija metoda za segmentaciju slike	91
	4.1	Mjere sličnosti	92
		4.1.1 Notacija	93
		4.1.2 Mjere temeljene na sličnosti područja	93
		4.1.3 Mjere temeljene na preklapanju rubova	94
		4.1.4 Statistički neparametarski testovi - Rand indeks	95
	4.2	Normalizirani probabilistički Rand indeks	95
		4.2.1 Probabilistički Rand Indeks	96
		4.2.2 Normalizacija	100
	4.3	Berkeley Segmentation Dataset	102
	4.4	Točnost i efikasnost	105
5	Kor	nparativna evaluacija	107
	5.1	Procjena kvalitete	108
		5.1.1 Najbolji rezultat	109
		5.1.2 Stabilnost s obzirom na upravljačke parametre	110
		5.1.3 Stabilnost algoritma s obzirom na različite slike	113
	5.2	Efikasnost	122
	5.3	Primjena u <i>RGB</i> prostoru boja	127
	5.4	Ovisnost rezultata o funkciji jezgre	128
6	Opt	imizacija asinkronim PRAM modelom	131
	6.1	Paralelno računanje	131
		6.1.1 Paralelne paradigme	132
		6.1.2 Asinkrono paralelno računalo sa slučajnim pristupom	133
	6.2	Optimizacija algoritma segmentacije asinkronom PRAM paradigmom	134
		6.2.1 Diskretna aproksimacija gustoće u APRAM paradigmi	135
		6.2.2 Preslikavanje klastera u prostornu domenu	139
	6.3	Analiza efikasnosti paralelnog algoritma	139
7	Ada	aptivno filtriranje i primjena u sustavu protupožarnog nadzora	145
	7.1	Adaptivno filtriranje	145
	7.2	Primjena na detekciju dima	151
		7.2.1 Inteligentni protupožarni nadzorni sustav	152
		7.2.2 Detekcija dima u vidljivom dijelu spektra	153
		7.2.3 Detekcija pokreta	154

		7.2.4 Adaptivno filtriranje smetnji	155
8	Zak	ljučak	163
\mathbf{A}	Seg	mentacija slike metodom srednjeg pomaka	167
	A.1	Estimacija gustoće u prostoru značajki	167
	A.2	Estimacija gradijenta gustoće	169
	A.3	Klasteriranje metodom srednjeg pomaka	170
	A.4	EDISON: Segmentacija slike	171
в	Efik	asna segmentacija slike particioniranjem grafa	173
	B.1	Particioniranje grafa	173
	B.2	Kriterij postojanja granice	174
	B.3	Algoritam segmentacije slike	175
\mathbf{Li}	terat	ura	175

Popis slika

2.1	Absorpcijski odziv fotoreceptora u vidljivom dijelu spektra: štapići $R(\lambda)$ i tri vrste čunjića $S_1(\lambda), S_2(\lambda), S_3(\lambda)$.	23
2.2	Reprezentacija boje u terminima nijanse ($\mathbf{H}ue$), zasićenja ($\mathbf{S}aturation$) i intenziteta ($\mathbf{I}ntensity$). Ovakva reprezentacija boje bliža je percep- tualnom poimanju boje u višim razinama vizualnog sustava čovjeka. HSI reprezentacija boje se iz osnovnog RGB sustava dobija nelinear- nim transformacijama.	24
2.3	Krivulje vrijednosti poticaja CIE primarnog spektralnog RGB sustava za boje u vidljivom dijelu spektra. Boje iz područja negativnih vrijednosti poticaja ne mogu biti reproducirane CIE primarnim sus-	
9.4	tavom.	25
2.4	nih izvora. Sve vrijednosti poticaja su pozitivne.	26
2.5	Dijagrami kromatičnosti sa referentnom bijelom točkom za (a) <i>CIE</i> <i>RGB</i> primarni spektralni sustav; (b) <i>CIE XYZ</i> spektralni sustav. Na slici (c) prikazan je dijagram kromatičnosti <i>CIE XYZ</i> sustava sa	07
26	Dijagram kromatičnosti <i>CIE XVZ</i> prostora sa ucrtanim MacAdam	27
2.0	elipsama jedva primjetnih razlika boje	27
2.7	MacAdam elipse jedva primjetnih razlika boje na (a) $CIE XYZ$ i (b) $CIE L^*u^*v^*$ dijagramu kromatičnosti. Varijacije u veličini, ekscentri- citetu i orijentaciji elipsi manje su u $L^*u^*v^*$ prostoru boja, ali prostor	
2.8	nije potpuno uniforman	28
2.9	$L^*u^*v^*$ prostor ne manifestira izrazita struktura	30
	segmentacija	31

2.10	Segmentacija slike metodom k-sredina: (a) ulazna slika, (b) segmen- tacija slike na dva segmenta (c) segmentacija slike na 10 segmenata, (d) segmentacija slike na 25 segmenata	33
2.11	Magnituda gradijenta dobivena korištenjem različitih operatora	$\frac{30}{37}$
3.1	Često korištene funkcije jezgre. Redom su po stupcima prikazani: kvadratni val $K_S(x)$, Epanechnikova jezgra $K_E(x)$, normalna jezgra $K_C(x)$	44
3.2	Funkcija gustoće 2D skupa uzoraka estimirana normalnom jezgrom. Prikazani su rezultati dobiveni za različite pojasne propusnosti h	46
3.3	Klasteriranje estimacijom gustoće: (a) ulazni podaci bez šuma; (b) podaci sa šumom; (c), (d) gustoća estimirana Epanechnikovom jez- grom (bez normalizacije) za podatke sa i bez prisustva šuma; (e), (f) klastorirani podaci sa i bez prisustva šuma	54
3.4	Segmentacija slike za različite vrijednosti faktora proporcionalnosti ρ . Za $\rho = 9$ javlja se presegmentiranost, tj. rezultirajuća segmentacija	94
3.5	sadrži veći broj detalja koji ne nose značajniji informacijski sadržaj Segmentacija slike za različite vrijednosti faktora proporcionalnosti ρ .	71
	Za $\rho = 1$ nisu otkrivene značajne cjeline na slici.	75
3.6	Segmentacija slike za različite vrijednosti faktora proporcionalnosti ρ .	
	Za sve tri vrijednosti parametra dobivaju se segmentacije prihvatljive	
	kvalitete. Za $\rho=1$ algoritma ne uočava jasnu granicu kopna i neba u	
	donjem desnom dijelu slike. Za $\rho=9$ na nekim dijelovima slike može	
	se uočiti izraženija presegmentiranost	76
3.7	Segmentacija slike za različite vrijednosti fiksne pojasne propusnosti $h_r^{(0)}$. Za sve vrijednosti parametra rezultirajuće segmentacije su pri-	
3.8	hvatljive kvalitete. Segmentacija slike za različite vrijednosti fiksne pojasne propusnosti $h_r^{(0)}$. Za sve vrijednosti parametra dobivaju se segmentacije prihvat-	11
	ljive kvalitete, uz izraženiju presegmentiranost za manje vrijednosti	
	parametra	78
3.9	Segmentacija slike za različite vrijednosti fiksne pojasne propusnosti $h_r^{(0)}$. Za $h_r^{(0)} = 16$ algoritam nije sposoban razlučiti granice broda,	-
9.10		79
3.10	Segmentacija slike za razlicite vrijednosti relativne razine suma ε	80
3.11	Segmentacija slike za razlicite vrijednosti relativne razine suma ε	81
3.12	Segmentacija slike za razlicite vrijednosti relativne razine suma ε	82
3.13	Normalizirani broj znacajnih zarista u domeni boja u ovisnosti o rela-	
	tivnoj razini suma ε . Broj značajnih žarišta normaliziran je s obzirom na broj značajnih žarišta za $\varepsilon = 1$. Prikazana je srednja vrijednost za sve slike u <i>Berkeley Segmentation Dataset</i> bazi slika opisanoj u	
	poglavlju 4.3.	82

3.14	Segmentacija slike za različite vrijednosti minimalne veličine segmenta ϑ zadane u broju piksela	83
3.15	Segmentacija slike za različite vrijednosti minimalne veličine segmenta ϑ zadane u broju piksela	84
3.16	Segmentacija slike za različite vrijednosti minimalne veličine segmenta ϑ zadane u broju piksela	85
3.17	Segmentacija slike za dva načina postprocesiranja u prostornoj do- meni: (b) postprocesiranje povezivanjem malih segmenata sa naj- sličnijim susjedom, (c) postprocesiranje efikasnom metodom segmen- tacije grafa. Razlika između segmentacija na slici (b) i (c) može se uočiti na licu mlađog diotota	86
3.18	Segmentacija slike za dva načina postprocesiranja u prostornoj do- meni: (b) postprocesiranje povezivanjem malih segmenata sa naj- sličnijim susjedom, (c) postprocesiranje efikasnom metodom segmen- tacije grafa. Iako se dobivene segmentacije u nekim detaljima razli-	00
3 1 9	kuju, nema značajnije razlike u kvaliteti.	87
0.15	efikasne segmentacije grafa, za različite vrijednosti parametra κ	88
3.20	Segmentacija slike uz postprocesiranje u prostornoj domeni metodom efikasne segmentacije grafa, za različite vrijednosti parametra κ	89
3.21	Segmentacija slike uz postprocesiranje u prostornoj domeni metodom efikasne segmentacije grafa, za različite vrijednosti parametra κ \ldots .	90
4.1	Primjer segmentacija sa različitom skalom detalja: (a) ulazna slika, (b) i (c) dvije "istinite" segmentacije koje su napravili različiti ljudi .	92
4.2 4.3	Dvije <i>istinite</i> segmentacije hipotetske slike \ldots Tolerantnost PR indeksa prema rafiniranju skale detalja. Redom su prikazane: (a) ulazna slika; dvije <i>istinite (ground truth)</i> segmentacije (b) i (c); segmentacije (d), (e) i (f) za koje se računa PR indeks temeljem dostupnih <i>istinitih</i> segmentacija. Sve podjele na testnim segmentacijama (d) i (f) prisutne su i na <i>istinitim</i> segmentacijama. Segmentacija (e) dijeli sliku vertikalno po sredini, na način koji nije prisutne u <i>istinitim</i> segmentacijama	97
4.4	Ulazna slika i pripadajuće <i>istinite</i> segmentacije koje su napravili ljudi (Berkeley Segmentation Dataset)	104
5.1	Maksimalni NPR indeks za sve kombinacije ulaznih parametara. Na slici (a) prikazani su rezultati za pojedinačne slike, poredani po rastućim vrijednostima NPR indeksa. Na slici (b) rezultati su prikazani u obliku histograma, pri čemu su na apscisi prikazane vrijednosti NPR indeksa, a na ordinati postotak slika za koji je postignut pripadajući	
5.2	<i>NPR</i> indeks	110 110

5.3	Osjetljivost algoritama na izbor ulaznih parametara. S lijeva na desno su za svaku od ovaluiranih motoda prikazani: (1) srodnja vrijodnost	
	NDP indolga za gua kombinacija ulaznih parametara i jedna stan	
	dardna davijacija ako gradnja unijednosti: (2) histogram digtribucija	
	aradniik uniidaasti NDDindeka (2) distrikusiis standardnik dari	
	srednjih vrijednosti <i>NPR</i> indeks; (3) distribucija standardnih devi-	
	Jacija. Po retcima su redom prikazam rezultati za sijedece metode:	
	AMBIS, AMBIS sa EGB postprocesiranjem u prostornoj domeni,	115
_ ,	metoda srednjeg pomaka (<i>Mean snift</i>), <i>EGB</i> metoda	. 115
5.4	AMBIS: osjetljivost na parametar $h_r^{(0)}$. Od vrha prema dnu redom	
	su prikazani rezultati za (1) AMBIS; (2) AMBIS+EGB, $\kappa = 100$; (3)	
	$AMBIS+EGB, \kappa = 200; (4) AMBIS+EGB, \kappa = 300 \dots \dots \dots \dots$. 116
5.5	AMBIS+EGB: osjetljivost na parametar κ . Od vrha prema dnu re-	
	dom su prikazani rezultati sa parametrom $h_r^{(0)}$ fiksiranim na vrijed-	
	nosti $h_r^{(0)} = 2, 4, 6, 10, 16.$. 117
5.6	$MS:$ osjetljivost na parametar h_s . Od vrha prema dnu redom su	
	prikazani rezultati sa parametrom h_r fiksiranim na vrijednosti $h_r =$	
	2, 4, 6, 10, 16	. 118
5.7	MS : osjetljivost na parametar h_r . Od vrha prema dnu redom su	
	prikazani rezultati sa parametrom h_s fiksiranim na vrijednosti $h_s =$	
	4, 8, 12, 16	. 119
5.8	AMBIS - srednji NPR za sve slike za različite vrijednosti parametra	
	$h_r^{(0)}$. 120
5.9	AMBIS+EGB - srednji NPR indeks za sve slike za različite vrijed-	
	nosti parametra $h_r^{(0)}$. 120
5.10	$M\!S$ - srednji NPR indeks za sve slike za različite vrijednosti parame-	
	tra h_r	. 121
5.11	EGB - srednji NPR za sve slike za različite vrijednosti parametra κ	. 121
5.12	Prosječno vrijeme izvršavanja za različite metode. Vrijeme izvršavanja	
	prikazano je u logaritamskoj skali	. 122
5.13	$AMBIS$ - vrijeme izvršavanja u ovisnosti parametru $h_r^{(0)}$. 123
5.14	AMBIS+EGB - prosječno vrijeme izvršavanja za sve kombinacije	
	ulaznih parametara $h_r^{(0)}$ i κ	. 124
5.15	$M\!S$ - prosječno vrijeme izvršavanja za sve kombinacije spektralne	
	pojasne propusnosti h_r i prostorne pojasne propusnosti h_s	. 125
5.16	EGB - prosječno vrijeme izvršavanja u ovisnosti o parametru κ	. 125
5.17	Srednje vrijeme izvršavanja u ovisnosti o dimenzijama. Za svaku od	
	metoda korišteni su parametri iz sredine optimalnog intervala. Za $M\!S$	
	algoritam odabrane vrijednosti parametara h_s, h_r nalaze se na donjoj	
	granici optimalnog intervala, dok se za više vrijednosti dobivaju duža	
	vremena obrade.	. 126
5.18	Kvaliteta rezultata dobivena primjenom metoda segmentacije u RGB	
	prostoru boja: (a) maksimalna vrijednost NPR indeksa, (b) srednja	
	vrijednost NPR indeksa	. 127

5.19	Usporedba rezultata dobivenih korištenjem normalne i Epanechni- kove jezgre: (a) maksimalna vrijednost NPR indeksa, (b) srednja vrijednost NPR indeksa.	. 128
5.20	Usporedba rezultata dobivenih korištenjem normalne i Epanechnikove jezgre za različite vrijednosti parametra $hr^{(0)}$. 129
6.1	Prosječno vrijeme izvršavanja pojedinih faza slijednog algoritma za različite vrijednosti parametra $h_r^{(0)}$. 134
6.2	Paralelno preslikavanje klastera domene boja u prostornu domenu podatkovnom dekompozicijom slike. Podjelom slike po visini i presli- kavanjem sa dva procesa rezultira vertikalnom podjelom jedinstvenih segmenata.	. 139
6.3	Prosječno vrijeme izvršavanja pojedinih faza algoritma za različite vrijednosti parametra $h_r^{(0)}$. Ključni koraci realizirani su u <i>APRAM</i> paradiemi ca dujio piti izurčavanja	140
6.4	Prosječno vrijeme izvršavanja pojedinih faza algoritma za različite vrijednosti parametra $h_r^{(0)}$. Ključni koraci realizirani su u APRAM	. 140
6.5	paradigmi sa četiri niti izvršavanja	. 141
6.6	paradigmi sa osam niti izvršavanja	. 142
6.7	Izvršavanja ključnih koraka	. 143
	ulazno-izlaznih operacija je do 30%.	. 144
7.1	Konvolucija slike: (a) fiksnom jezgrom, rezultirajuća vrijednost pro- matranog piksela dobija se usrednjavanjem svih susjeda; (b) adap- tivnom jezgrom, rezultirajuća vrijednost dobija se usrednjavanjem susjeda koji pripadaju istom segmentu ulazne slike	147
7.2	Adaptivno filtriranje: (a) ulazna slika, (b) filtrirana slika, (c) slika filtrirana primjenom adaptivnog filtra	148
7.3	Adaptivno filtriranje: (a) ulazna slika, (b) slika filtrirana korištenjem fiksne jezgre, (c) slika filtrirana primjenom adaptivnog filtra	. 149

7.4	Adaptivno filtriranje: (a) ulazna slika, (b) slika filtrirana korištenjem
	fiksne jezgre, (c) slika filtrirana primjenom adaptivnog filtra 150
7.5	Struktura Inteligent nog protupožarnog nadzornog sustava $I\!PN\!AS$. . 151
7.6	Motrilačka stanica na lokaciji <i>Marjan</i> i upravljačko sučelje sustava
	$IPNAS \ldots 152$
7.7	Požar u nastajanju detektiran sustavom IPNAS (Buzet, Istra) 153
7.8	Lažni alarm, detektirana je prašina nastala prolaskom vozila (Buzet,
	Istra)
7.9	Dinamička analiza slijeda slika, nadzorna postaja Crni Vrh, Naci- onalni park Paklenica. Po recima: ulazna slika, rezultat dinamičke analize, rezultat dinamičke analize na slikama filtriranim adaptivnim
	filtrom
7.10	Nastavak sekvence sa prethodne slike. Odnos površine sa detektira- nom promjenom na izvornim slikama (drugi redak) i na filtriranim
	slikama (treći redak) dan je u tablici 7.1
7.11	Požar u početnoj fazi, Kaštela, 26.07.2006. slijed slika sa nadzorne kamere na Marjanu. Po recima: ulazna slika, rezultat dinamičke analize, rezultat dinamičke analize na slikama filtriranim adaptivnim filtrom
7.12	Nastavak sekvence sa prethodne slike. Dinamičkom analizom na neobrađenim slikama detektira se dim, ali i šum u urbanom području. Primjenom postupka adaptivnog filtriranja smanjuje se količina šuma uz jednaku učinkovitost u detekciji dima
A.1	Analiza slike u $L^*u^*v^*$ prostoru boja. Slika je preuzeta iz izvornog rada [2]

Popis tablica

2.1	Transformacije prostora boja	29
2.2	Neki od uobicajenih operatora za racunanje gradijenta. Uokvireni element označava ishodište.	36
4.1	Empirijske vjerojatnosti temeljene dostupnim na <i>istinitim</i> segmenta- cijama za sliku 4.3(a)	99
5.1	Skup upravljačkih parametara za svaku od metoda korišten u prove- denim eksperimentima	109
5.2	Vrijednosti upravljačkih parametara	124
7.1	Detekcije pokreta na protupožarnoj nadzornoj kameri na postaji <i>Crni</i> <i>vrh, NP Paklenica.</i> Prikazani je broj detektiranih piksela za nefiltri- rane slike i slike filtrirane adaptivnim niskopropusnim filtrom. Zadnji stupac prikazuje relativan odnos drugog i prvog stupca. Na slikama nema stvarne promjene	156

Poglavlje 1 Uvod

Kada bi u jednoj rečenici trebali pojasniti računalni vid, općenitom definicijom mogli bi ga opisati kao postupak izdvajanja semantičkih informacija iz digitalne slike. Ovom jednostavnom definicijom obuhvaćen je cijeli niz procesa i postupaka, od uočavanja raznovrsnih značajki i tragova najniže razine, do donošenja kompleksnih zaključaka temeljnih na sabiranju, uočavanju i obradi osobina sa korisnim informacijskim sadržajem. Složenost zadataka koji se računalnim vidom rješavaju, ali i važnost pronalaženja efikasnih računalnih algoritama, najbolje je opisana podatkom da vizualna informacija čini oko 75% svih senzorijalnih informacija koje čovjek primi tijekom života [1]. Ovu ogromnu količinu informacija, koja je naš osnovni izvor percepcije stvarnosti, ljudski mozak obrađuje kvalitetno, efikasno i potpuno transparentno, a krajnji cilj računalnog vida je oponašanje ljudskog vida, u smislu postizanja razine kvalitete, robusnosti i efikasnosti usporedive sa ljudskom vizualnom percepcijom.

Za razliku od robusnosti kojom vizualnu informaciju obrađuje mozak, sustavi računalnog vida u pravilu su ograničeni na rješavanje jasno definiranog zadatka, uz relativno veliku osjetljivost na promjene u parametrima okoline. Složenost problema obrade vizualne informacije leži u činjenici da je vizualna percepcija ireverzibilan problem, kod kojeg se pobuda koju fotoni izazivaju na mrežnici oka ne može inverzno, matematičkom formulom, povezati sa osobinama udaljene pobude koja je uzrokovala da fotoni u oko uđu. Vizualne senzorijalne informacije ljudski mozak, kao i sustavi računalnog vida, tumače kao najvjerojatniju konfiguraciju objekata u okolini, pri čemu se za odabir najvjerojatnije hipoteze koriste dvije skupine informacija: (a) značajke niske razine i statističke regularnosti u pobudi i (b) informacije i znanje više razine.

Objašnjenje činjenice da je učinkovitost i robusnost sustava računalnog vida još uvijek daleko od ljudske vizualne percepcije leži u načinu obrade vizualne informacije. Hijerarhijsku strukturu zadaća računalnog vida moguće je podijeliti u tri osnovne kategorije [1]:

- Zadaće niske razine bave se izdvajanjem jednostavnih značajki i tragova, kao što su rubovi, krivulje ili homogena područja, na jednoj slici.
- Zadaće srednje razine za cilj imaju prikupljanje i grupiranje semantički značajnih karakteristika na jednoj ili više slika, kao što su uočavanje pokreta ili grupiranje povezanih osobina.
- Zadaće visoke razine interpretiraju informacije izdvojene algoritmima niže razine i donose kompleksne zaključke.

Sličnu klasifikaciju teško je primijeniti na ljudski vid, iako je sustav vizualne percepcije i kod živih bića moguće fiziološki raščlaniti na zasebne cjeline. Učinkovitost obrade vizualne informacije kod živih bića posljedica je jake obosmjerne povezanosti raznih obradbenih jedinica i obimnog toka informacija iz viših razina obrade prema nižim. Povratni tok sa informacijama izvedenim na višim razinama obrade upravlja obavljanjem zadaća niže razine, a cjelokupan proces obrade izgleda kao integrirana cjelina. Usprkos snažnom razvoju algoritama i metoda obrade vizualne informacije, kod modernih sustava računalnog vida tok informacija je još uvijek gotovo isključivo od nižih prema višim razinama obrade [1].

Perceptualna podjela slike na homogene cjeline osnovni je korak u procesu razumijevanja vizualne informacije. Ovaj postupak je jedna od temeljnih zadaća niske razine, a baziran je na različitim jednostavnim značajkama kao što su boja, tekstura ili rubovi. Podjela slike na segmente od kojih svaki čini cjelinu definiranu zajedničkim karakteristikama predstavlja smanjenje volumena ulazne informacije uz zadržavanje bitnog informacijskog sadržaja. O kvaliteti rezultata segmentacije koji predstavljaju komprimiranu reprezentaciju ulaznih podataka, a koriste se kao ulazna informacija u višim razinama obrade, uvelike ovisi učinkovitost cjelokupnog sustava računalnog vida.

Razvoj učinkovitih metoda računalnog vida često je baziran na proučavanju i razumijevanju principa vizualne percepcije biološkog svijeta. Ovdje se, međutim, postavlja pitanje koliki je utjecaj i na koji način uključiti implicitno znanje akumulirano u višim razinama spoznaje u procese niske razine. Kada čovjek promatra kompleksnu scenu, proces segmentacije na homogene regije temelji se na koherenciji informacija o svjetlini, boji, teksturi, pokretu i drugim osobinama i tragovima niske razine te iskustvu i spoznajama pohranjenim u višim razinama svijesti. Ovo razmatranje sugerira da segmentacija slike bazirana samo na manjem podskupu dostupnih tragova niske razine ne može rezultirati potpunom i perceptualno točnom segmentacijom. Do kvalitetne podjele scene na regije moguće je doći samo kombiniranjem svih dostupnih informacija niske razine, dok se rezultati srednjih i viših nivoa obrade mogu koristiti za upravljanje procesima i određivanje značaja i težina pojedinih tragova, sinergijom kojih se dobiva perceptualno logična segmentacija. Zbog kompleksnosti vizualne informacije, u procesu znanstvenog zaključivanja potrebno je prema načelu *ceteris paribus*¹ u kontroliranim eksperimentima ograničiti stupanj složenosti pobude te raščlambom na jednostavne dijelove koji čine cjelinu ulazne informacije promatrati informacijski sadržaj svakog dijela. Hijerarhijska struktura računalnog vida i mogućnost upravljanja procesima niže razine povratnom informacijom iz procesa više razine uvjetuju definiranje jasnog i jednostavnog skupa upravljačkih parametara.

U ovom radu izložena je nova metoda brze segmentacije slike, korištenjem informacije o boji svakog piksela, neovisno o drugim postupcima obrade. Metoda segmentacije za cilj ima reduciranje varijacija u boji u ulaznim podacima, uočavanje homogenih cjelina te jezgrovitu reprezentaciju rezultata obrade koji se koriste kao ulaz u procese više razine. Razvijena Adaptivna metoda segmentacije slike mrežom diskretnih elemenata (eng. Adaptive Mesh Based Image Segmentation - AMBIS) temeljena je na procjeni gustoće diskretizacijom domene boja.

Zbog prirode vizualne informacije i kontinuiranog dotoka novih podataka, važnu karakteristiku svakog algoritma za obradu slike čini njegova efikasnost, tj. brzina obrade podataka. Razvijena metoda implementirana je računalnim algoritmom i evaluirana temeljem dva osnovna kriterija: (a) kriterij kvalitete rezultata te (b) kriterij efikasnosti.

U drugom dijelu rada pažnja je posvećena prilagodbi predložene metode segmentacije modernim računalnim arhitekturama s mogućnošću paralelne obrade podataka. Razvoj algoritma za računalno sklopovlje s višestrukim obradnim jedinicama za cilj ima povećanje efikasnosti postupka segmentacije, uz zadržavanje dostignute razine kvalitete rezultata. U zasebnoj cjelini prikazana je primjena predložene metode u sustavu za ranu detekciju šumskih požara korištenjem kamera u vidljivom dijelu spektra.

Rad je organiziran na sljedeći način: U poglavlju 2 izloženi su osnovni principi i metode segmentacije slike. Predložena metoda segmentacije temeljena na procjeni gustoće domene boja opisana je u poglavlju 3. Metodologija istraživanja razrađena je u poglavlju 4, a rezultati komparativne evaluacije predložene metode prezentirani su u poglavlju 5. U poglavlju 6 istražena je mogućnost implementacije predložene metode segmentacije slike u asinkronom paralelnom modelu. U poglavlju 7 opisan je način korištenja izložene metode za konstrukciju adaptivnog filtra, s primjenom u sustavu za rano otkrivanje šumskih požara. U poglavlju 8 dan je zaključak.

Rad sadrži i priloge u kojima su prikazane dvije postojeće metode segmentacije slike. U dodatku A opisan je postupak segmentacije slike temeljen na metodi

¹Latinski: uz nepromijenjene ostale uvjete

srednjeg pomaka. Ova metoda je zbog svoje djelotvornosti prihvaćena od strane znanstvenika i inženjera koji se bave problemima računalnog vida, a primjenjena je u brojnim sustavima. Metoda efikasne segmentacije temeljene na grafu, opisana u dodatku B, koristi adaptivni prag segmentacije. Ova metoda polazi od pretpostavke da segmentacija slike, kao zadaća niske razine računalnog vida, pored kvalitete rezultata mora zadovoljiti i kriterij efikasnosti, tj. brzine obrade približno jednake drugim zadaćama niske razine. U usporedbi sa metodom srednjeg pomaka, kvaliteta segmentacija dobivenih ovom metodom nešto je niža, uz povećanu efikasnost.

Metode opisane u dodacima A i B, kao predstavnici različitih pristupa problemu segmentacije, koriste se za komparativnu evaluaciju predložene metode *AMBIS*. Za obje opisane metode dostupne su programske implementacije pripremljene su od strane samih autora, čime je osigurana objektivnost evaluacije s obzirom na kvalitetu implementacije.

Poglavlje 2 Segmentacija slike

Segmentacija je proces dijeljenja slike na homogene segmente (cjeline ili regije). Ova operacija niske razine ekvivalentna je uočavanju rubova, tj. pronalaženju granica između nepovezanih regija na slici. U velikom broju problema računalnog vida i obrade slike, upravo segmentacija predstavlja prvi korak čiji se rezultati obrađuju metodama više razine kao što su semantička interpretacija, raspoznavanje ili klasifikacija objekata na slici. Jedna od mogućih formalnih definicija segmentacije može se dati na slijedeći način [34]:

Definicija 1 (Segmentacija slike). Neka je \mathcal{I} slika te \mathcal{H} određeno obilježje homogenosti. Tada je particija \mathcal{P} od \mathcal{I} u skup od K područja $\mathcal{S}_i, i = 1, ..., K$ segmentacija slike \mathcal{I} ako vrijedi:

$$1. \bigcup_{i=1}^{K} \mathcal{S}_i = \mathcal{I}$$

- 2. $\forall i \text{ vrijedi } \mathcal{H}(\mathcal{S}_i) = istina$
- 3. Za susjedne S_i i S_j vrijedi $\mathcal{H}(S_i \bigcup S_j) = la \tilde{z}$

Navedeni uvjeti osiguravaju da (1) segmentacija uključuje cijelu sliku; (2) svaka zasebna regija na slici mora biti homogena s obzirom na obilježje \mathcal{H} ; (3) dva susjedna segmenta ne mogu biti povezana u cjelinu koja zadovoljava obilježje \mathcal{H} . Općeniti opis postupka segmentacije može se dati i definiranjem svojstva koje rezultirajuća segmentacija ulazne slike mora zadovoljiti [41]: "Segmentirana područja na slici trebala bi biti jednolika i homogena s obzirom na neku karakteristiku kao što je boja ili tekstura. Unutrašnjost područja bi trebala biti jednostavna i bez mnogo malih rupa. Susjedna područja na segmentaciji trebala bi se značajnije razlikovati s obzirom na karakteristiku koja je u nutrini područja uniformna. Granice područja trebale bi biti jednostavne, što manje hrapave, i prostorno točne." Ipak, zbog prirode problema, točnu definiciju segmentacije teško je dati, a u literaturi se često kao cilj segmentacije navodi podjela slike na regije na način koji je koristan za specifičnu primjenu.

Iako informacija o boji sadrži detaljniju reprezentaciju značajki slike, sve do nedavno, najveći dio metoda segmentacije predloženih u literaturi bazirao se na segmentaciji slike sivih razina¹. Glavni uzrok ovome leži u činjenici da obrada slike u boji zahtjeva složenije postupke procesiranja i značajno duže vrijeme računanja. U novije vrijeme, brzi razvoj i pad cijena računalnog sklopovlja fokus u razvoju novih metoda segmentacije pomiču na procesiranje slike u boji. Sukladno ovome, pojavio se veći broj metoda za segmentaciju slike u boji. Veliki dio predloženih metoda temelji se na poopćavanju postojećih rješenja za segmentaciju slike sivih razina na višedimenzionalni problem slike u boji, dok dio autora predlaže nove tehnike bazirane na specifičnostima informacije o boji.

U poglavlju 2.1 izloženi su temeljni principi percepcije i prezentacije informacije o boji. Pregled postojećih metoda segmentacije dan je u poglavlju 2.2.

2.1 Percepcija boje

Vizualna informacija u obliku slike predstavlja prostornu distribuciju fizikalnih veličina kao što su osvijetljenost² i frekvencijske karakteristike. Svjetlost je elektromagnetsko zračenje koje stimulira fotoreceptore vizualnog sistema, a može se izraziti kao spektralna distribucija energije $L(\lambda)$, gdje je λ valna dužina u vidljivom područja elektromagnetskog spektra, za prosječnog promatrača od 350 nm do 780 nm [35, poglavlje 3]. Svjetlost primljena od objekta može se definirati sa (2.1)

$$I(\lambda) = \rho(\lambda)L(\lambda), \qquad (2.1)$$

gdje $\rho(\lambda)$ predstavlja karakteristiku reflektivnosti objekta, a $L(\lambda)$ ulaznu distribuciju energije elektromagnetskog zračenja.

Sliku objekta u obliku reflektirane svjetlosti ljudsko oko percipira putem dvije vrste fotoreceptora na mrežnici. Štapići³ imaju veću osjetljivost i odziv u području niskog osvjetljenja, a zaduženi su za $tamni^4$ vid. Čunjići⁵ su manje osjetljivi i odziv imaju u području bolje osvjetljenosti, a odgovorni su i za percepciju boje. U

 $^{^1}grey$ -level image, u literaturi na hrvatskom jeziku se često koristi izraz $crno-bijela\ slika,$ koji ne odražava svojstva prikaza slike u nijansama svjetline

 $^{^{2}}luminance$

 $^{^{3}}rods$

 $^{^4}scotopic$

 $^{^{5}}$ cones



Slika 2.1: Absorpcijski odziv fotoreceptora u vidljivom dijelu spektra: štapići $R(\lambda)$ i tri vrste čunjića $S_1(\lambda), S_2(\lambda), S_3(\lambda)$.

ljudskom oku postoje tri različite vrste čunjića [34] čiji se maksimalni odziv nalazi u području *žuto-zelene, zelene* i *plave* boje [35, poglavlje 3]. Važno je naglasiti da ljudsko oko nema sposobnost rekonstrukcije komponenti boje, a valna duljina svjetlosti monokromatskog izvora i percipirana boja nisu jedinstveni jedno s obzirom na drugo, tj. vizualni sustav može odrediti valnu duljinu iz percipirane boje [35, poglavlje 3]. Tipičan absorpcijski spektar štapića i čunjića prikazan je na slici 2.1.

Percepcija boje kroz tri osnovne komponente ne odražava način percepcije boje u procesima više razine ljudskog sustava za obradu vizualnih informacija. U ovom smislu, boja je bolje predstavljena u terminima nijanse (*Hue*), zasićenja (*Saturation*) i intenziteta (*Intensity*) [39] [36, poglavlje 1]. Perceptualna reprezentacija poimanja boja u obliku nijanse, zasićenja i intenziteta *HSI* prikazana je slikom 2.2. Nijansa boje određena je kutem u odnosu na referentnu točku, najčešće (ali ne uvijek) u odnosu na crvenu, a primarne boje zatvaraju kut od $2\pi/3$. Zasićenje odgovara udaljenosti od vertikalne osi intenziteta, koja predstavlja nijanse sive, od crne (I = 0) prema bijeloj (I = 1). *HSI* i *RGB* prostori boja povezani su nelinearnim transformacijama danim u tablici 2.1.



2.1.1 Reprezentacija boja

Reprezentacija boje temeljena je na pretpostavci da se svaka boja može dobiti miješanjem tri primarne boje u odgovarajućem omjeru [37], što je u skladu sa biološkim karakteristikama oka. Relativan odnos primarnih boja za dobivanje određene boje $C(\lambda)$ definiran je sa tri vrijednosti poticaja⁶ $T_1(\lambda), T_2(\lambda), T_3(\lambda)$ [38, poglavlje 6].

Primarne boje preporučene kao CIE^7 standardni RGB izvori dani su monokromatskim izvorima [35, poglavlje 3]:

$P_1(\lambda) = \delta(\lambda - \lambda_1),$	$\lambda_1 = 700.0 \text{ nm}$	(crvena - R)
$P_2(\lambda) = \delta(\lambda - \lambda_2),$	$\lambda_2 = 546.1 \text{ nm}$	(zelena - G)
$P_3(\lambda) = \delta(\lambda - \lambda_3),$	$\lambda_3 = 435.8 \text{ nm}$	(plava - B)

Krivulje tri vrijednosti poticaja za *CIE* primarni spektralni *RGB* sustav prikazane su slikom 2.3. Za dio frekvencijskog područja vidljivog dijela spektra neke od vrijednosti poticaja su negativne, a ove boje nije moguće reproducirati korištenjem *CIE* primarnog sustava.

⁶tristimulus value

⁷Commission Internationale de L'Eclairage



Slika 2.3: Krivulje vrijednosti poticaja CIE primarnog spektralnog RGB sustava za boje u vidljivom dijelu spektra. Boje iz područja negativnih vrijednosti poticaja ne mogu biti reproducirane CIE primarnim sustavom.

Iako se za bilo koju boju može pronaći odgovarajući set tri primarna izvora, ne postoji praktičan set izvora kojim se mogu reproducirati sve boje [35, poglavlje 3]. Sa ciljem razvoja sustava primarnih izvora sa pozitivnim vrijednostima poticaja u vidljivom dijelu spektra definiran je *CIE XYZ* sustav hipotetskih primarnih izvora. Ovi izvori pogodni su za kolorimetrijske kalkulacije, a nisu fizikalno realizibilni. *XYZ* koordinate povezane su sa koordinatama u *RBG* sustavu linearnim transformacijama danim u tablici 2.1, pri čemu *Y* koordinata predstavlja svjetlinu. Vrijednosti poticaja za *CIE XYZ* sustav primarnih izvora u vidljivom dijelu spektra dane su na slici 2.4.

2.1.2 Dijagram kromatičnosti

Kromatske boje definirane su sa (2.2)

$$t_k = \frac{T_k}{T_1 + T_2 + T_3}, \quad k = 1, 2, 3 \tag{2.2}$$



Slika 2.4: Krivulje vrijednosti poticaja za *CIE XYZ* sustav hipotetskih primarnih izvora. Sve vrijednosti poticaja su pozitivne.

pri čemu vrijedi $t_1 + t_2 + t_3 = 1$ pa su samo dvije od tri kromatske koordinate nezavisne. Kromatske koordinate projiciraju trodimenzionalnu boju na dvodimenzionalnu ravninu, a komponente t_1, t_2 predstavljaju kromatsku komponentu boje. Cijeli prostor boja zadan je koordinatama (t_1, t_2, Y) , pri čemu se za bilo koju vrijednost Y = konstanta dobija kromatska ravnina, sa pripadajućim podprostorom boja predstavljenim dijagramom kromatičnosti⁸. Dijagrami kromatičnosti za *CIE RGB* i *CIE XYZ* spektralne sustave prikazani su slikom 2.5. Dio spektra koji se može reproducirati primarnim izvorima sustava omeđen je ravnim linijama koje povezuju točke (0,0), (0,1), (1,0) i naziva se *gama boja*⁹ sustava. Referentna bijela točka u dijagramu kromatičnosti *CIE RGB* primarnog sustava ima koordinate $(\frac{1}{3}, \frac{1}{3})$ i odgovara boji R = G = B = 1. Odnos game *XYZ* i *RGB* sustava prikazan je slikom 2.5(c), na kojoj je u gami *XYZ* sustava izdvojeno spektralno područje koje se može reproducirati *RGB* sustavom primarnih izvora.

⁸chromaticity diagram

⁹ color gamut



Slika 2.5: Dijagrami kromatičnosti sa referentnom bijelom točkom za (a) CIE RGB primarni spektralni sustav; (b) CIE XYZ spektralni sustav. Na slici (c) prikazan je dijagram kromatičnosti CIE XYZ sustava sa ucrtanom gamom CIE RGB sustava





2.1.3 Udaljenosti u prostoru boja

Kvantitivna mjera različitosti dvije proizvoljno odabrane boje predstavlja temeljni uvjet analize slika u boji. Iako vektorski zapis informacije o boji omogućava primjenu jednostavne metrike, osnovni problem predstavlja perceptualna neuniformnost prostora boja. Na slici 2.6 prikazan je kromatički dijagram *CIE XYZ* prostora boja sa ucrtanim *MacAdam* elipsama jedva primjetnih razlika boje¹⁰, u smislu da se bilo koja boja koja leži na rubu elipse jedva razlikuje od boje u centru elipse [35, poglavlje 3]. Iz slike je vidljivo da veličina, orijentacija i ekscentricitet ovih elipsi značajno varira u različitim dijelovima prostora boja.

¹⁰just noticable color differences



Slika 2.7: MacAdam elipse jedva primjetnih razlika boje na (a) CIE XYZ i (b) $CIE L^*u^*v^*$ dijagramu kromatičnosti. Varijacije u veličini, ekscentricitetu i orijentaciji elipsi manje su u $L^*u^*v^*$ prostoru boja, ali prostor nije potpuno uniforman.

Neuniformnost prostora u smislu nejednake udaljenosti među perceptualno jednako različitim bojama u različitim točkama prostora boja ograničava učinkovitost metoda analize slike temeljenih na boji. Sa ciljem ostvarivanja perceptualne uniformonsti definirani su približno uniformni prostori boja čija je osnovna karakteristika da udaljenost među bojama odgovara perceptualnom poimanju razlike u boji od strane prosječnog promatrača, približno uniformno na cijelom prostoru boja, od kojih su najčešće u upotrebi $CIE \ L^*a^*b^*$ i $CIE \ L^*u^*v^*$. Ovi prostori povezani su sa $CIE \ XYZ$ prostorom boja nelinearnim transformacijama. Transformacije za osnovne prostore boja dane su u tablici 2.1.

Na slici 2.8 prikazana je distribucija piksela slike u tri prostora boja. Neuniformnost udaljenosti među perceptualno sličnim bojama kao posljedica strukture prostora može se najbolje uočiti na primjeru piksela koji odgovaraju moru (nijanse sivo-plave). U RGB prostoru (slika 2.8(b)), ovi pikseli slične boje distribuirani su duž glavne dijagonale, često sa razmjerno velikim međusobnim udaljenostima u odnosu na perceptualno različitije boje. Izduženost u smjeru glavne dijagonale karakteristika je svih klastera piksela perceptualno slične boje, a posljedica je strukture RGB prostora. U HSI prostoru (slika 2.8(c)) pikseli koji odgovaraju more distribuirani su u području male saturacije, s relativno velikim udaljenostima s obzirom na komponentu nijanse (Hue), a i u ovom slučaju distribucija svih piksela u prostoru pokazuje strukturu prostora boja. Pikseli boje mora izrazitije su grupirani samo u CIE $L^*u^*v^*$ prostoru, a distribucija svih piksela ne manifestira izraženu strukturu prostora boja.

<i>CIE RGB</i> primarni spektralni sistem	Monokromatski primarni izvori valnih duljina $\lambda_1 = 700.0 \text{ nm}, \lambda_2 = 546.1 \text{ nm}, \lambda_3 = 435.8 \text{ nm}, \text{ sa}$ referentnom bijelom točkom $R = G = B = 1$
HSI	$\theta = \arccos\left[\frac{\frac{1}{2}\left[(R-G) + (R-B)\right]}{\sqrt{(R-G)^2 + (R-G)(G-B)}}\right]$ $H = \begin{cases} \theta & \text{za } B \le G\\ 2\pi - \theta & \text{za } B > G \end{cases}$ $I = \frac{R+G+B}{3}$ $S = 1 - \frac{\min\left(R,G,B\right)}{I}$
CIE XYZ	$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.490 & 0.310 & 0.200 \\ 0.177 & 0.813 & 0.011 \\ 0.000 & 0.010 & 0.990 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix}$
CIE L*a*b*	$L^* = \begin{cases} 116 \left(\frac{Y}{Y_0}\right)^{\frac{1}{3}} & \operatorname{za} \frac{Y}{Y_0} > 0.008856\\ 903.3\frac{Y}{Y_0} & \operatorname{za} \frac{Y}{Y_0} \le 0.008856 \end{cases}$ $a^* = 500 \left[f\left(\frac{X}{X_0}\right) - f\left(\frac{Y}{Y_0}\right) \right]$ $b^* = 200 \left[f\left(\frac{Y}{Y_0}\right) - f\left(\frac{Z}{Z_0}\right) \right]$
	gdje je X_0, Y_0, Z_0 referentna bijela, te $f(U) = \begin{cases} U^{\frac{1}{3}} & \text{za } U > 0.008856\\ 7.787U + \frac{16}{116} & \text{za } U \leq 0.008856 \end{cases}$
CIE L [*] u [*] v [*]	$L^{*} = \begin{cases} 116 \left(\frac{Y}{Y_{0}}\right)^{\frac{1}{3}} & \text{za } \frac{Y}{Y_{0}} > 0.008856\\ 903.3\frac{Y}{Y_{0}} & \text{za } \frac{Y}{Y_{0}} \le 0.008856 \end{cases}$ $u^{*} = 13L^{*} \left[\frac{4X}{X+15Y+3Z} - \frac{4X_{0}}{X_{0}+15Y_{0}+3Z_{0}}\right]$ $v^{*} = 13L^{*} \left[\frac{9Y}{X+15Y+3Z} - \frac{9Y_{0}}{X_{0}+15Y_{0}+3Z_{0}}\right]$

gdje je X_0,Y_0,Z_0 referentna bijela





Slika 2.8: Konverzije prostora boja: (a) ulazna slika, (b) pikseli slike u RGB prostoru (c) pikseli slike u HSI prostoru, (d) pikseli slike u $L^*u^*v^*$ prostoru. Komponente boje u svim prostorima boja su normalizirane na vrijednost [0, 1]. Iz distribucije piksela slike u prostoru može se uočiti struktura prostora za RGB i HSI prostore boja, dok za se $CIE L^*u^*v^*$ prostor ne manifestira izrazita struktura.

2.2 Metode segmentacije

Problem segmentacije slike usko je povezan sa općenitim problemom klasteriranja, organiziranja skupa uzoraka u homogene podgrupe. Pronalaženje dobrih podgrupa u skupu uzoraka je NP težak problem¹¹. Zbog značaja i široke primjene, u znanstvenoj literaturi je predložen veliki broj različitih pristupa, pregled koji je dostupan u [47, 48, 49, 50]. Segmentacija slike se bavi dekompozicijom scene u njezine sastavne dijelove ili regije. Dvije najčešće značajke koje se pri tom koriste su boja i tekstura. U ostatku poglavlja ukratko su izložene osnovni pristupi i metode, sa naglaskom na segmentaciju slike temeljem informacije o boji, a slične tehnike koriste se i kod

 $^{^{11}} Non-deterministic Polynomial Hard, problem nije deterministički rješiv u polinomskom vremenu$

segmentacije bazirane na teksturi. Pored metoda koje koriste samo jednu od ove dvije značajke, u literaturi je predložen cijeli niz hibridnih rješenja koja kombiniraju rezultate više različitih algoritama segmentacije.

Metode segmentacije slike prema pristupu možemo grubo podijeliti [34] u tri osnovne kategorije: (1) metode bazirane na prostoru značajki; (2) metode koje rade u prostornoj domeni slike; (3) metode bazirane na fizici fenomena. Prvu skupinu čine metode koje ulaznu informaciju (piksele ulazne slike) kodiraju u neki prostor značajki u kojem raznim tehnikama uočavaju grupe piksela sa zajedničkim karakteristikama. Druga skupina oslanja se na pretpostavku da su točke koje odgovaraju cjelovitim objektima (regijama) na slici prostorno povezane sa izaženom koherentnošću površine. Ove tehnike koriste se procesom dijeljenja ili rasta područja uz zadovoljavanje postavljenog uvjeta homogenosti. Zasebnu skupinu čine algoritmi koji u postupku segmentiranja ulazne slike uzimaju u obzir fizikalne karakteristike refleksije svijetla na površinama na sceni.

2.2.1 Amplitudna segmentacija



(a) Ulazna slika sivih razina



(b) Histogram intenziteta



(c) Segmentirana slika



Najjednostavniji pristup segmentaciji slike sivih razina baziran je na korištenju histograma relativnih frekvencija svjetlina točaka na slici [35, 41]. Histogram predstavlja standardni način zapisa statističke distribucije frekvencija nijansi sive koji se dobija diskretizacijom domene u konačan broj ćelija i prebrojavanjem piksela slike koji populiraju svaku od ćelija (na sličan način može se izračunati i histogram distribucije boja diskretizacijom 3D domene boja u 3D ćelije). Ovisno o složenosti slike i rješenja koje tražimo, možemo govoriti o bimodalnom i multimodalnom histogramu. Kod bimodalne segmentacije krećemo od pretpostavke da svjetlina točaka pada u jednu od dvije grupe (svijetle i tamne točke). Određivanjem minimuma između dva vrha histograma, prema pripadnosti piksela skupini ulazna slika dijeli se na dva segmenta. Dobar primjer korištenja bimodalne segmentacije je izdvajanje teksta na svjetlijoj pozadini, što je prvi korak u procesu računalnog prepoznavanja teksta. Kod multimodalne segmentacije, histogram svjetlina točaka sadrži više izraženih vrhova. Proces segmentiranja temelji se na određivanje pripadnosti svakog piksela ulazne slike jednom od dominantnih vrhova, pri čemu dodatni problem predstavlja određivanje broja vrhova i kriterija prihvaćanja lokalnog maksimuma kao dominantnog vrha. Ilustracija postupka amplitudne segmentacije dana je na slici 2.9. Za određivanje pripadnosti piksela dominantnim vrhovima koriste se razne iterativne metode, od kojih je najčešće u upotrebi metoda k-sredina¹² [42, 56]. Metode amplitudne segmentacije moguće je poopćiti za primjenu na sliku u boji [43, 46]. U ovom slučaju konačni rezultat se dobija kombiniranjem histograma frekvencija po različitim komponentama boje.

2.2.2 Grupiranje u vektorskom prostoru

Ova skupina metoda ulazne podatke predstavlja vektorima u nekom prostoru značajki. Kod primjene na segmentaciju slike, pikseli slike najčešće su predstavljeni 3D vektorima koji kodiraju informaciju o boji, ili 5D vektorima združene domene boja i prostorne domene (koordinate piksela na slici). Particijski algoritmi svrstavaju vektore u disjunktne kategorije iterativnom optimizacijom zadanog kriterija. Najčešće korišteni optimizacijski kriterij je minimizacija kvadratne greške, definirane sa

$$\sum_{i=1}^{K} \sum_{x \in \mathcal{S}_i} \|x - m_i\|^2 \tag{2.3}$$

gdje vektor m_i odgovara centroidu *i*-tog klastera (skupine podataka ili segmenta) \mathcal{S}_i te x vektor ulaznog podatka (piksela slike). Ove metode najbolje rezultate postižu kada su podaci organizirani u hipersferične klastere. Osnovni nedostatak je mogućnost zaustavljanja algoritma u lokalnom minimumu. Najčešće korištena metoda kvantizacije vektora je algoritam k-sredina koji iterativno pridjeljuje ulazne podatke nekom od klastera, do postizanja minimalne kvadratne greške, ili maksimalnog dopuštenog broja iteracija. Najveći nedostatak ove metode je potreba da se pri pokretanju algoritma unaprijed zada broj jedinstvenih klasa K, kao i određivanje početnog skupa točaka za pokretanje algoritma. Rezultat particioniranja ulazne slike metodom k-sredina za različite vrijednosti parametra k dan je na slici 2.10. Algoritam k-sredina je u literaturi prisutan u brojnim varijantama koje na razne načine optimiziraju algoritam [57], ili predlažu rješenje problema odabira inicijalnih točaka algoritma i broja klasa K [58]. Autori ovaj problem pokušavaju riješiti inicijalnim pokretanjem algoritma sa manjim podskupom ulaznih podataka i iterativnim pokretanjem algoritma sa ciljem pronalaženja optimalnih ulaznih parametara. Algoritam k-sredina, kao i većina metoda iz ove skupine, osjetljivi su na šum i udaljene

 $^{^{12}}k$ -means



Slika 2.10: Segmentacija slike metodom k-sredina: (a) ulazna slika, (b) segmentacija slike na dva segmenta (c) segmentacija slike na 10 segmenata, (d) segmentacija slike na 25 segmenata

predstavnike klastera. U upotrebi je često i $fuzzy\ c$ -means [59, 60] verzija algoritma k-sredina u neizrazitoj logici.

2.2.3 Particioniranje grafa

Ova skupina metoda temelji se na teoriji grafa [65, 66], a problem pronalaženja podgrupa u skupu uzoraka generalno predstavlja u terminima grafa, gdje je graf G = (V, E) uređeni par skupa vrhova $V \neq \emptyset$ i skupa rubova E. Svaki čvor $v_i \in V$ predstavlja jedan ulazni podatak (piksel slike), a težina svakog ruba u E se računa prema značajkama para piksela (npr. razlika u intenzitetu ili boji) koje dani rub povezuje [13, 14, 48]. Pored metoda koje koriste fiksni prag težine ruba za particioniranje grafa, a predložene su i tehnike sa adaptivnim kriterijem particioniranje [12, 13], koje se temelje na pretpostavci da sve zasebne regije na slici nemaju približno jednake varijacije značajki unutar piksela regije. Efikasna metoda segmentacije slike particioniranjem grafa [12] dokaz o postojanju granice između dvije regije zasniva na usporedbi dvije vrijednosti: (1) razlici intenziteta (razine sivog) ili boje (3D vektor) preko granice i (2) razlici intenziteta ili boje među pikselima unutar svake regije. Ova metoda ne temelji se na unaprijed poznatom broju segmenata, a kod pokretanja postupka segmentacije zadaje se samo skala opservacije. Metode segmentacije koje ne polaze od implicitnih pretpostavki o strukturi podataka svrstavamo u skupinu neparametarskih metoda. Detalji metode efikasne segmentacije slike particioniranjem grafa dani su u dodatku B.

Pored spomenutih metoda, dobri rezultati ostvareni su primjenom kriterija normaliziranog reza [10] i metoda baziranih na svojstvenim vektorima [64] i spektralnom particioniranju grafa [10, 11]. Ipak, metode bazirane na ovoj tehnici su računalno složene čime je djelomično ograničena primjena na probleme s velikom količinom ulaznih podataka.

2.2.4 Grupiranje analizom gustoće

Široku skupinu metoda za grupiranje u vektorskom prostoru čine metode temeljene na analizi prostora značajki. Ove metode bazirane su na pretpostavki da su varijacije boje ili neke druge karakteristike svakog objekta na slici male u odnosu na razliku u boji prema drugim objektima. Ova osobina manifestira se reprezentacijom objekata kao oblaka točaka u nekom vektorskom prostoru. Nepoznata funkcija distribucije gustoće aproksimira se temeljem opaženih podataka (piksela slike kodiranih u vektorski prostor). Područja veće gustoće odgovaraju izdvojenim regijama slike, razgraničenih područjima male gustoće. Dio rješenja predloženih u literaturi polazi od pretpostavke da su točke koje odgovaraju individualnim objektima distribuirane prema nepoznatoj distribuciji, a ulazni podaci aproksimiraju se modelom koji odgovara mješavini normalnih distribucija [61, 62, 63]. Pronalaženje dobre podjele podataka na klastere (segmente slike) prema ovom modelu ekvivalentno je određivanju parametara distribucija. Ova skupina metoda bazirana je na implicitnoj pretpostavci o broju segmenata i načinu nastanka ulaznih podataka koja ne mora nužno biti točna, a prilagodba parametara kombinacije normalnih distribucija na stvarne podatke ne daje uvijek dobar rezultat [61].

Drugu skupinu metoda čine neparametarski algoritmi koji ne polaze od bilo kakvih implicitnih pretpostavki o strukturi vektorskog prostora i načinu generiranja podataka. Metoda *srednjeg pomaka*¹³ [15] uspješno primjenjena na problem segmentacije slike [2, 3, 4] računanjem gradijenta estimirane funkcije gustoće pronalazi

 $^{^{13}}mean \ shift$

maksimume gustoće u prostoru značajki i za svaki maksimum određuje skup gravitirajućih točaka. Zbog jasnih matematičkih temelja i efikasnosti, ova je metoda našla široku primjenu u raznim problemima računalnog vida [17], kao i drugim područjima kod kojih se traži kvalitetno particioniranje seta ulaznih podataka na grupe sa zajedničkim karakteristikama. Detalji *Mean Shift* algoritma dani su u dodatku A, a rezultati segmentacije slike ovom metodom korišteni su za komparativnu evaluaciju predloženog algoritma segmentacije slike metodom procjene gustoće.

2.2.5 Segmentacija izrastanjem područja

Homogene cjeline na slici moguće je dobiti procesom rasta područja¹⁴ [41, 55] iz unaprijed odabranih točaka. Ove tehnike češće se koriste za izdvajanje jedne homogene regije na slici, na način da proces rasta počinje iz jedne predefinirane točke i povezuje u cjelinu susjedne točke sve dok je zadovoljen određeni kriterij homogenosti (npr. jednolikost boje ili teksture). Do segmentacije cijele slike moguće je doći uzastopnim pokretanjem procesa rasta iz različitih točaka sve dok svi pikseli slike nisu uključeni u neku od homogenih cjelina. Tehnike izrastanja područja moguće je podijeliti u tri grupe [41] s obzirom na kriterij uspoređivanja točaka: (a) uspoređivanje sličnosti susjednih točaka; (b) uspoređivanje sličnosti okolina susjednih točaka; (c) uspoređivanje sličnosti točke i centroida regije. Neke od metoda izrastanja područja koriste masku za detekciju rubova za izdvajanje točaka koje čine granicu među područjima.

Metode bazirane na izrastanju područja imaju širu upotrebu u problemima klasifikacije i prepoznavanja objekata na slici. Kod primjene na segmentaciju javlja se problem odabira skupa točaka koje se koriste kao polazne točke za rast područja, a krajnji rezultat segmentacije u pravilu ovisi i o redoslijedu odabira početnih točaka.

2.2.6 Segmentiranje dijeljenjem i stapanjem

Ova skupina metoda koristi prikaz slike pomoću strukture *kvadratnog stabla*¹⁵[35]. Proces segmentacije započinje dijeljenjem nehomogene ulazne slike na manje regije do zadovoljavanja uvjeta homogenosti unutar svakog segmenta. Ovaj postupak u pravilu rezultira velikim brojem malih homogenih regija, na koje se primjenjuje proces spajanja susjednih područja koja zadovoljavaju kriterij homogenosti. Ilustracija metoda dijeljenja i spajanja dana je na slici 2.11. Ulazna slika dijeli se na (a) četiri segmenta, nakon čega se regije koje ne zadovoljavaju uvjet homogenosti dalje dijele

¹⁴region growing

 $^{^{15}}$ quadtree



Slika 2.11: split-and-merge segmentacija slike

na manje dijelove (b, c). U posljednjoj primjenjuje se postupak stapanja (d).

U literaturi su prisutni brojni algoritmi segmentacije slike bazirani na tehnici dijeljenja i stapanja, koje se međusobno razlikuju po odabiru kriterija homogenosti. Većina metoda razvijena je za segmentaciju slike sivih razina.

	H_1	H_2
Roberts	$\left[\begin{array}{cc} 0 & 1 \\ -1 & 0 \end{array}\right]$	$\left[\begin{array}{cc} 1 & 0 \\ 0 & -1 \end{array}\right]$
Prewitt	$\left[\begin{array}{rrrr} -1 & 0 & 1 \\ -1 & \boxed{0} & 1 \\ -1 & 0 & 1 \end{array}\right]$	$\left[\begin{array}{rrrr} -1 & -1 & -1 \\ 0 & \boxed{0} & 0 \\ 1 & 1 & 1 \end{array}\right]$
Sobel	$\begin{bmatrix} -1 & 0 & 1 \\ -2 & \boxed{0} & 2 \\ -1 & 0 & 1 \end{bmatrix}$	$\left[\begin{array}{rrrr} -1 & -2 & -1 \\ 0 & \boxed{0} & 0 \\ 1 & 2 & 1 \end{array}\right]$

2.2.7 Segmentiranje otkrivanjem granica

Tablica 2.2: Neki od uobičajenih operatora za računanje gradijenta. Uokvireni element označava ishodište.

Može se pokazati da je problem segmentacije ekvivalentan problemu pronalaženja granica među homogenim regijama [34, 35]. Metode koje se baziraju na ovoj činjenici polaze od pronalaženja rubova koji se manifestiraju kao diskontinuiteti na ulaznoj slici, nakon čega se različitim metodama uočeni diskontinuiteti povezuju u neprekinute granice među zasebnim dijelovima slike. Postupak pronalaženja rubova najčešće se bazira na aproksimaciji gradijenta ulazne slike sivih razina. Gradijent se


(c) Prewitt operator

(d) Sobel operator



računa konvolucijom ulazne slike sa parom matrica H_1 i H_2 koje daju iznos promjene u ortogonalnim smjerovima. Magnituda vektora gradijenta računa se prema (2.4)

$$g(m,n) = \sqrt{g_1^2(m,n) + g_2^2(m,n)}$$

$$= \sqrt{\langle U, H_1 \rangle_{m,n}^2 + \langle U, H_1 \rangle_{m,n}^2},$$
(2.4)

gdje je U slika sivih razina te

$$\langle U, H \rangle_{m,n} = \sum_{i} \sum_{j} h(i,j) u(i+m,j+n)$$
(2.5)

Konačan rezultat detekcije rubova dobiva se izdvajanjem piksela slike sa gradijentom višim od vrijednosti praga, koja može biti unaprijed zadana ili se određuje adaptivno. Neki od često korištenih operatora za računanje gradijenta dani su u tablici 2.2. Na slici 2.12 prikazana je magnituda gradijenta izračunata korištenjem različitih operatora. Sličan postupak moguće je primijeniti i na sliku u boji, pri čemu je gradijent definiran kroz (a) jednu mjeru koja određuje varijacije svih komponenti boje, ili (b) proračun gradijenta za svaku od komponenti boje i kombiniranje rezultata prema nekom kriteriju. Nakon otkrivanja rubova na ulaznoj slici, dobivene točke rasporeda rubova moguće je povezati metodama interpolacije da bi se dobila zatvorena kontura koja definira regiju.

2.2.8 Neuralne mreže

Metode bazirane na umjetnim neuralnim mrežama [48, 52, 53] čine zasebnu klasu algoritama za obradu digitalne slike, a osnovna im je motivacija imitiranje funkcije bioloških neuronskih mreža. Umjetne neuralne mreže su strukture izgrađene od većeg broja jednostavnih elementarnih procesora ili neurona međusobno povezanih višestrukim vezama. U literaturi se može pronaći veliki broj tipova i topologija umjetnih neuralnih mreža, a u digitalnoj obradi slike se najčešće koriste za klasifikaciju elemenata slike u jednu od N predefiniranih kategorija. Klasifikacija se temelji na fazi učenja, kod koje se nadgledanim procesom određuju težinski faktori veza u strukturi neuralne mreže. U produkcijskoj fazi neuralna mreža prema naučenom nelinearnom modelu klasificira ulazne podatke.

Od metoda koje korijen vuku iz područja umjetne inteligencije, u literaturi je, pored neuralnih mreža, predloženo i nekoliko metoda za klasteriranje i klasifikaciju podataka baziranih na principima evolucijskog računanja [47, 54]

2.2.9 Fizikalne metode

Sve opisane metode segmentacije podložne su greškama uzrokovanim varijacijama u osvjetljenju objekata, sjenama i ostalim fizikalnim fenomenima koji utječu na vizualnu informaciju koju kamera, ali i ljudsko oko percipiraju kao ulaznu sliku. Ovi fenomeni remete uniformnost boja na homogenim površinama, što često, bez obzira na korišteni algoritam segmentacije, u konačnici rezultira presegmentiranjem slike, tj. podjelom cjelovitih objekata na više manjih segmenata. Dio autora ovaj problem pokušava riješiti analizom načina refleksije svjetla na površinama prikazanim na slici. Metode koje se koriste u postupku segmentacije često su baziraju na nekom od ranije spomenutih algoritama, a razliku u odnosu na klasične metode čini uključeni fizikalni model refleksije.

Poglavlje 3

Adaptivna segmentacija slike mrežom diskretnih elemenata

U ovom poglavlju opisana je predložena metoda adaptivne segmentacije slike mrežom diskretnih elemenata AMBIS (Adaptive Mesh Based Image Segmentation). Postupak segmentacije odvija se u dva koraka: (1) klasteriranje piksela slike u domeni boja analizom estimirane funkcije gustoće i (2) postprocesiranje u prostornoj domeni slike. Metoda se temelji na procjeni gustoće korištenjem jezgre [40, 44] i diskretizaciji prostora boja. Pojasna propusnost jezgre određuje se adaptivno iz samih podataka, čime je smanjena osjetljivost na odabir parametara algoritma. Gravitirajuća područja u prostoru boja preslikavaju se u domenu slike, gdje se postprocesiranjem dobiva konačni rezultat segmentacije.

Ostatak poglavlja organiziran je na slijedeći način: U poglavlju 3.1 dan je kratki pregled metoda klasteriranja temeljenih na analizi gustoće i diskretizaciji prostora značajki. Osnovni pojmovi i definicije na kojima se temelji postupak estimacije gustoće jezgrom, kao i postupak otkrivanja statističkih zakonitosti u ulaznim podacima analizom funkcije gustoće dani su u poglavlju 3.2. Tehnika efikasne procjene gustoće i klasteriranja podataka diskretizacijom prostora značajki izložena je u poglavlju 3.3, a detalji predložene metode segmentacije slike dani u poglavlju 3.4. U poglavlju 3.5 napravljena je analiza složenosti predložene metode segmentacije slike. Pregled upravljačkih parametara algoritma sa primjerima segmentacija dan je u poglavlju 3.6.

3.1 Metode klasteriranja temeljene na gustoći i rasterizaciji prostora

Klasteriranje je postupak nenadgledanog učenja koji za cilj ima razvrstavanje nekog skupa podataka u podskupove, kada predefinirane klase nisu unaprijed poznate. Ova tehnika koristi se za otkrivanje informacija i ekstrakciju znanja u neorganiziranim skupovima podataka, a igra značajnu ulogu u brojnim znanstvenim disciplinama i tehnološkim procesima. U literaturi postoji više srodnih definicija problema klasteriranja, pri čemu bi se osnovni koncept mogao opisati kao postupak organiziranja skupa uzoraka u grupe čiji su članovi međusobno sličniji nego članovi različitih grupa. Kvalitetan algoritam klasteriranja trebao bi udovoljavati sljedećim zahtjevima:

- Skalabilnost
- Prihvaćanje različitih tipova atributa
- Otkrivanje grupa podataka (klastera) proizvoljnog oblika
- Minimalni zahtjevi za poznavanje domene pri određivanju parametara algoritma
- Neosjetljivost na šum i udaljene objekte¹
- Neosjetljivost na redoslijed ulaznih podataka
- Mogućnost primjene na podatke visoke dimenzionalnosti

U praksi ne postoji generički algoritam koji zadovoljava sve navedene uvjete pa se različita metode klasteriranja prilagođavaju aplikaciji i karakteristikama podataka.

Zbog svog značaja, problem klasteriranja ekstenzivno se istražuje dugi niz godina, a u literaturi su predložena brojna rješenja. Generalno, postojeće metode klasteriranja možemo podijeliti u hijerarhijske, particijske i metode temeljene na gustoći, unutar kojih posebnu skupinu čine metode rasterizacije prostora. Složenost metoda temeljenih na rasterizaciji prostora u pravilu ovisi o skali rasterizacije, a ne o broju ulaznih podataka. Razvoj ovih metoda motiviran je brzim rastom količine dostupnih podataka i zahtjevima za kvalitetnom i efikasnom obradom istih. Ove metode, često potječu iz područja baza podataka, a karakteristika im je mali broj prolaza kroz podatke i velika brzina obrade.

Algoritam DBSCAN [67] klastere definira kao područja sa većom gustoćom uzoraka, razdvojena područjima manje gustoće koja mogu sadržavati šum. Područja veće gustoće definiraju se maksimalnim radijusom ϵ i minimalnim brojem uzoraka MinPts unutar ϵ -susjedstva. Parametre ϵ i MinPts specificira korisnik, a algoritam

 $^{^1 \,} outliers$

je sposoban otkriti skupine podataka proizvoljnog oblika. Rezultati klasteriranja nisu jedinstveni, već ovise o redoslijedu ulaznih podataka. Uz pretpostavku uniformne distribucije uzoraka unutar klastera, DBCLASD [68] koristi pristup sličan DBSCAN metodi, bez potrebe zadavanja ulaznih parametara algoritma. Pojam gustoće točaka i ϵ -susjedstva generaliziran je GDBSCAN [69] algoritmom, čime je omogućena primjena na grupiranje prostorno proširenih objekata proizvoljnog oblika (npr. 2D poligona) prema njihovim strukturnim osobinama.

DENCLUE [18, 19] metoda, bazirana na opservaciji da funkciji gustoće u nekoj točki prostora značajnije doprinose samo objekti u neposrednoj blizini, procjenu gustoće temelji na diskretizaciji prostora i tehnici srednje pomaknutih histograma² [44, 45]. Postupak klasteriranje temelji se na identifikaciji djelova histograma sa visokom podrškom, tj. gustoćom većom u odnosu na okolinu, koji se sa okolnim ćelijama povezuju u klastere. Rezultat klasteriranja ne ovisi o redoslijedu ulaznih podataka, a ova metoda otporna je na visoku razinu šuma. Algoritam klasteriranja upravljan je sa dva parametra: parametar τ definira doseg funkcije utjecaja i granularnost diskretizacije, dok parametar ξ određuje razinu šuma, tj. definira razinu iznad koje se gustoća podataka smatra dokazom o postojanju klastera. Metoda klasteriranja adaptivnim rafiniranjem rastera (A Grid-based Clustering Algorithm using Adaptive Mesh Refinement) [20] temelji se na prebrojavanju uzoraka koji populiraju ćelije višedimenzionalnog histograma adaptivne granularnosti. Parametri algoritma su početna granularnost i maksimalna razina rafiniranja diskretizacije, a algoritam zahtjeva više prolaza kroz podatke, pri čemu se u svakom prolazu ćelije histograma se većom podrškom (populirane sa većim brojem uzoraka) dijele na više manjih ćelije. Tehnika adaptivnog particioniranja ćelija histograma koristi se i u metodi statističkog klasteriranja slijeda podataka³ (Statistical grid-based clustering over data streams) [21], a rezultat ovisi o redoslijedu obrade uzoraka. STING [70] algoritam dijeli prostor u pravokutne ćelije sa hijerarhijskom strukturom, pri čemu se svaka ćelija više razine dijeli na ćelije niže razine prema statističkim obilježjima dobivenim obradom uzoraka koji pripadaju promatranoj ćeliji. Prostorni odnos susjednih ćelija na određenoj razini zrnatosti se ne razmatra, što za posljedicu ima nemogućnost otkrivanja dijagonalnih granica među klasterima. Problem određivanja granularnosti diskretizacije se u WaveCluster metodi [22] rješava korištenjem valića⁴, što rezultira sa više razina segmentacije različite skale detalja koje se dobivaju uzastopnim primjenama transformacije valićima.

CLIQUE [23] algoritam pronalazi klastere podataka u podprostorima izvornog prostora značajki, a temelji se na pretpostavki da postojanje klastera u nekom d-dimenzionalnom prostoru implicira postojanje klastera u svim d-1 dimenzionalnim projekcijama tog prostora. Ovaj algoritam skalabilan je za klasteriranje

 $^{^{2}}average \ shifted \ histograms$

 $^{^{3}}$ data stream

 $^{^4} wavelets$

visokodimenzionalnih podataka. GCA [24] metoda dimenzionalnost podataka reducira primjenom analize glavnih komponenata⁵ [49, poglavlje 3.6], nakon čega se diskretizacijom prostora reducira broj iteracija i računalna složenost algoritma ksredina. Skalabilnost s obzirom na dimenzionalnost podataka *OptiGrid* metoda [25] rješava uvođenjem pojma *razdvajajućih ravnina*. Ova metoda pronalazi (d-1)dimenzionalne hiperravnine koje u područjima manje gustoće dijele *d*-dimenzionalni prostor \mathbb{R}^d . Algoritam rekurzivno pronalazi *q* razdvajajućih ravnina od kojih je svaka ortogonalna na najmanje jednu projekciju \mathbb{R}^d , a zaustavlja se kada više nije moguće pronaći dobru razdvajajuću ravninu, tj. kada je gustoća svih mogućih razdvajajućih ravnina iznad predefiniranog praga.

Pored spomenutih, u literaturi su predložene i druge metode koje rješenje problema klasteriranja velikog broja uzoraka temelje na kvantizaciji prostora i pronalaženju područja veće gustoće ulaznih podataka. Zajedničko obilježje ovih metoda je mala računalna složenost i brza obrada, dok osnovni problem leži u odabiru ulaznih parametara algoritma. Pojasna propusnost (doseg funkcije jezgre), granularnost diskretiziranog prostora i prag funkcije gustoće temeljni su parametri koje dijeli većina metoda baziranih na procjeni gustoće i diskretizaciji prostora, a odabir ovih vrijednosti može značajno utjecati kako na kvalitetu rezultata, tako i na efikasnost algoritma. Poznavanje strukture prostora značajki i karakteristika podataka može značajno olakšati izbor parametara i povećati kvalitetu dobivenih rezultata. S druge strane, kod klasteriranja stvarnih podataka, *a priori* znanje o strukturi podataka u pravilu je ograničeno dostupno, što otežava izbor parametara i implementaciju algoritma klasteriranja te može značajno umanjiti upotrebljivost dobivenih rezultata.

3.2 Klasteriranje procjenom gustoće

Tehnika klasteriranja procjenom gustoće temelji se na pretpostavci da su podaci čija se podjela na disjunktne podgrupe traži skup slučajnih uzoraka generiranih prema nepoznatoj distribuciji vjerojatnosti neke slučajne varijable. Ekstrapolacijom informacije sadržane u uočenim uzorcima estimira se nepoznata distribucija, a analizom estimirane gustoće vjerojatnosti uočavaju se statističke zakonitosti na promatranom skupu. Najjednostavniji oblik podjele ulaznih podataka na podgrupe analizom gustoće je bimodalna ili multimodalna segmentacija histograma relativnih frekvencija, opisana u poglavlju 2.2.1, kod koje se nepoznata distribucija estimira diskretizacijom prostora i jednostavnim prebrojavanjem uzoraka u svakoj diskretnoj ćeliji (jedinici diskretizacije). U ostatku poglavlja dane su potrebne definicije i izloženi temeljni principi klasteriranja estimacijom nepoznate distribucije jezgrom i diskretizacijom prostora značajki.

⁵principal component analysis

3.2.1 Estimacija gustoće jezgrom

Tehnika *estimacije gustoće jezgrom*⁶, poznata i kao tehnika *Parzenovog* prozora [1, 40], način je procjene distribucije gustoće vjerojatnosti slučajne varijable temeljem dostupnog skupa uzoraka. Ekstrapolacija dostupnih podataka na cijelu populaciju temelji se na modeliranju doprinosa svakog uzorka funkcijom jezgre, a funkcija gustoće u nekoj točki prostora (domeni slučajne varijable) računa se kao suma doprinosa svih uzoraka.

Definicija 2 (Estimirana funkcija gustoće vjerojatnosti). Neka je $D = \{x_1, ..., x_N\}$ skup N uzoraka neke slučajne varijable predstavljenih vektorima $x_i \in \mathbb{R}^d$ u ddimenzionalnom prostoru značajki. Neka je **H** simetrična pozitivno definitna matrica pojasnih širina⁷ te K(x) funkcija jezgre. Tada je estimirana funkcija gustoće vjerojatnosti određena sumom doprinosa svih podataka

$$f^{D}(x) = \frac{1}{N} \sum_{i=1}^{N} K_{\mathbf{H}}(x - x_{i})$$
(3.1)

gdje je

$$K_{\mathbf{H}}(x) = |\mathbf{H}|^{-\frac{1}{2}} K(\mathbf{H}^{-\frac{1}{2}}x)$$
(3.2)

Definicija 3 (Jezgra). Jezgra je nenegativna funkcija $K : \mathbb{R}^d \to \mathbb{R}$ varijable $x \in \mathbb{R}^d$ takva da vrijedi

$$\int_{\mathbb{R}^d} K(x)dx = 1 \qquad \lim_{\|x\|\to\infty} \|x\|^d K(x) = 0 \qquad (3.3)$$
$$\int_{\mathbb{R}^d} xK(x)dx = 0 \qquad \int_{\mathbb{R}^d} xx^T K(x)dx = c_K \mathbf{I}$$

 $gdje je c_K$ konstanta.

Specijalni slučaj matrice pojasnih širina, uz uvjet Euklidske metrike prostora [2], dobija se za

$$\mathbf{H} = h^2 \mathbf{I},\tag{3.4}$$

U ovom slučaju matrica pojasnih širina zadana je pojasnom propusnosti h > 0, a radijalno simetrična jezgra K(x) zadana je sa

$$K(x) = c_{k,d}k(||x||^2), (3.5)$$

⁷ bandwidth matrix

⁶kernel density estimation

gdje je k(x) profil jezgre K, definiran za $x \ge 0$. Normalizacijska konstanta $c_{k,d}$ je strogo pozitivna i osigurava zadovoljavanje uvjeta danih sa (3.3). Uvrštavanjem (3.4) i (3.5) u (3.2) dobiva se

$$f_{h,K}^{D}(x) = \frac{1}{Nh^{d}} \sum_{i=1}^{N} K\left(\frac{x-x_{i}}{h}\right)$$
(3.6)

$$= \frac{c_{k,d}}{Nh^d} \sum_{i=1}^N k\left(\left\|\frac{x-x_i}{h}\right\|^2\right)$$
(3.7)



Slika 3.1: Često korištene funkcije jezgre. Redom su po stupcima prikazani: kvadratni val $K_S(x)$, Epanechnikova jezgra $K_E(x)$, normalna jezgra $K_G(x)$

Funkcija jezgre može biti bilo koja funkcija koja zadovoljava (3.3). Na slici 3.1 prikazane su često korištene jezgre zadane sa:

1. Kvadratni val (slike 3.1(a), 3.1(d)):

$$K_S(x) = \begin{cases} c_d^{-1} & \|x\| \le 1\\ 0 & \|x\| > 1 \end{cases},$$
(3.8)

zadan profilom

$$k_S(x) = \begin{cases} 1 & 0 \le x \le 1\\ 0 & x > 1 \end{cases}$$
(3.9)

2. Epanechnikova jezgra (slike 3.1(b), 3.1(e)):

$$K_E(x) = \begin{cases} \frac{1}{2}c_d^{-1}(d+2)(1-\|x\|^2) & \|x\| \le 1\\ 0 & \|x\| > 1 \end{cases}$$
(3.10)

zadana profilom

$$k_E(x) = \begin{cases} 1 - x & 0 \le x \le 1\\ 0 & x > 1 \end{cases},$$
(3.11)

Konstanta c_d se kod kvadratnog vala i Epanechnikove funkcije jezgre koristi kao normalizacijska konstanta i ovisi o dimenzionalnosti podataka d, a jednaka je volumenu jedinične d-dimenzionalne sfere.

3. Normalna jezgra (slika 3.1(c), 3.1(f)):

$$K_G(x) = (2\pi)^{-\frac{d}{2}} e^{-\frac{1}{2}||x||^2},$$
(3.12)

zadana profilom

$$k_G(x) = e^{-\frac{1}{2}x} \tag{3.13}$$

Estimirana funkcija gustoće ovisi o jezgri K(x) i pojasnoj propusnosti h, pri čemu konačni oblik estimata znatno više ovisi o parametru h nego o korištenoj jezgri [26]. Pojasna propusnost h određuje doprinos jezgre K u susjedstvu uzorka x_i čime se efektivno definira izglađenost estimirane funkcije gustoće. Za veću vrijednost parametra h širi se područje doprinosa pojedinog uzorka, funkcija gustoće postaje izglađena, a manji klasteri mogu nestati pod uticajem veće skupine uzoraka. Za manje vrijednosti h doprinos svakog uzorka funkciji gustoće ima manji doseg, sa izraženijim lokalnim utjecajem. U ovom slučaju, funkcija gustoće otkriva više detalja u strukturi ulaznih podataka. U ekstremnom slučaju $h \to 0$, svaki lokalni maksimum funkcije gustoće izračunate za N = 267 dvodimenzionalnih uzoraka ($x \in \mathbb{R}^2$) dobivene korištenjem normalne jezgre za tri različite vrijednosti parametra h. Prikazani su redom: (a) ulazni podaci te estimirana funkcija gustoće za (b) h = 0.03, (c) h = 0.06, (d) h = 0.1.

3.2.2 Optimalna pojasna propusnost h

Funkcija gustoće dana jednadžbom (3.6) definira gustoću u svakoj točki $x \in \mathbb{R}^d$ kao srednju vrijednost doprinosa radijalno simetričnih jezgri K centriranih u N točaka koje odgovaraju ulaznim podacima. Pri tom je pojasna propusnost h definirana kao fiksna vrijednost konstantna za sve točke $x \in \mathbb{R}^d$. Iz primjera na slici 3.2 razvidno je da odabir parametra h može značajno utjecati na rezultirajuću funkciju gustoće, tj. odabir pojasne propusnosti efektivno određuje skalu opservacije.



Slika 3.2: Funkcija gustoće 2D skupa uzoraka estimirana normalnom jezgrom. Prikazani su rezultati dobiveni za različite pojasne propusnosti h

Procjenu kvalitete estimirane funkcije gustoće možemo promatrati kao standardni problem procjene kvalitete estimata $\hat{\theta}$ parametra θ . Pri tom je $\hat{\theta} = f^D(x)$ procijenjen temeljem dostupnog skupa uzoraka $D = \{x_1, ..., x_N\}$, a vrijednost θ generirana prema stvarnoj distribuciji f(x), koju nazivamo svojstvena ili inherentna funkcija gustoće. Mjera sličnosti funkcije gustoće vjerojatnosti $f^D(x)$, estimirane prema (3.6) radijalno simetričnom jezgrom K(x) (3.5), temeljem skupa uzoraka D, i stvarne distribucije vjerojatnosti f(x) u točki x dana je srednjom kvadratnom greškom⁸ definiranom sumom varijance i kvadrata odstupanja⁹ [26, 44]:

$$MSE(x) = E \left[f^{D}(x) - f(x) \right]^{2}$$

$$= Var \left(f^{D}(x) \right) + \left[Bias \left(f^{D}(x), f(x) \right) \right]^{2},$$
(3.14)

gdje je E operator očekivanja. Korištenjem Taylorovog rastava funkcije, odstupanje

⁸mean squared error

 $^{^9} bias$

i varijanca mogu se aproksimirati [27, poglavlje 4] sa:

$$\operatorname{Bias}(x) \approx \frac{1}{2}h^2\mu_2(K) \bigtriangleup f(x)$$
(3.15)

$$\operatorname{Var}(x) \approx \frac{1}{Nh^d} R(K) f(x)$$
 (3.16)

 $\mu_2(K)$ i R(K) su konstante koje ovise o jezgri K zadane sa [5]:

$$\mu_2(K) = \int_{\mathbb{R}^d} z_1^2 K(z) dz \qquad R(K) = \int_{\mathbb{R}^d} K(z) dz, \qquad (3.17)$$

gdje je z_1 prva komponenta vektora z.

Integriranjem MSE(x) na cijeloj domeni $x\in\mathbb{R}^d$ računa se srednja integrirana kvadratna greška¹⁰ [26]:

MISE =
$$\int_{\mathbb{R}^d} \text{MSE}(x) = \int_{\mathbb{R}^d} E\left[f^D(x) - f(x)\right]^2 dx$$
$$= E\left[\int_{\mathbb{R}^d} \left[f^D(x) - f(x)\right]^2 dx\right]$$
(3.18)

Računanjem MISE (3.18) jezgrom pojasne propusnosti h koja zadovoljava uvjete

$$\lim_{N \to \infty} h(N) = 0 \qquad \lim_{N \to \infty} Nh^d(N) = \infty \qquad \lim_{N \to \infty} Nh^{2d}(N) = \infty$$
(3.19)

dobija se asimptotska srednja integrirana kvadratna greška $(AMISE)^{11}$ [17, 26]. Ova mjera daje procjenu razlike funkcije gustoće i njezine estimirane vrijednosti kada broj uzoraka N ide u beskonačno, a pojasna propusnost h u nula nešto sporijim ritmom [1]. Asimptotska srednja integrirana kvadratna greška minimizirana je za Epanechnikovu (3.10) jezgru [15][27, poglavlje 4].

Optimalna vrijednost pojasne propusnosti h predstavlja kompromis između greške odstupanja i varijance te minimizira srednju integriranu kvadratnu grešku. Prema (3.15) greška odstupanja proporcionalna je h^2 , što znači da se odstupanje smanjuje za manje vrijednosti h. S druge strane, prema (3.16), varijanca je proporcionalna $N^{-1}h^{-d}$ i povećava se za manje vrijednosti pojasne propusnosti. Direktna primjena jednadžbe (3.18) za određivanje optimalne vrijednosti parametra h u praksi nije

¹⁰mean integrated squared error

 $^{^{11}}asymptotic\ mean\ integrated\ squared\ error$

moguća, pošto ovisi o nepoznatoj distribuciji f(x) čija se aproksimacija traži.

Problem određivanja optimalne vrijednosti parametra h kod estimacije gustoće jezgrom ekstenzivno je obrađen u literaturi [26, 28, 29, 30, 31, 32], a predložene metode mogu se podijeliti u dvije široke klase:

 Metode temeljene na unakrsnoj validaciji¹² [26, 28] za cilj imaju maksimizaciju zadanog kriterija. Izvorno predložen validacijski kriterij [31] traži parametar h koji maksimizira

$$LCV(h) = \prod_{i=1}^{N} \hat{f}_{h,-i}^{D}(x_{i}), \qquad (3.20)$$

gdje je $\hat{f}_{h,-i}^D(x_i)$ funkcija gustoće estimirana bez točke x_i .

• Metode uključivanja¹³ [26, 28] temeljene su na asimptotskom minimiziranju srednje integrirane kvadratne greške (3.18) predstavljene u terminima odstupanja i varijance (3.14), aproksimiranim Taylorovim rastavom (3.15), (3.16). Parametrom h_1 računa se probni estimat¹⁴ koji se uključuje u proračun srednje integrirane kvadratne greške te se iterativnom procedurom pronalazi optimalni h_{opt} koji grešku minimizira.

Pored statistički utemeljenih tehnika, u predloženi su i drugi pristupi. Jedan od načina odabira pojasne propusnosti temelji se na stabilnosti dekompozicije [18] gdje se kao optimalna vrijednost parametra h predlaže sredina najšireg intervala u kojem se za dane podatke dobiva jednak broj klastera. Drukčiji pristup temelji se na odabiru h temeljem procjene kvalitete dekompozicije. Tipične mjere kvalitete dekompozicije baziraju se na odnosu sličnosti podatka unutar klastera i podataka pridruženih različitim klasterima [47, 48].

Primjena spomenutih, teoretski utemeljenih tehnika odabira pojasne propusnosti u problemima računalnog vida je u najboljem slučaju ograničena na određivanje razumnih granica skupa mogućih vrijednosti ovog parametra [17]. Ulazni podaci za zadaće računalnog vida u pravilu su nepotpuni, sa malim podudaranjem sa teoretskim distribucijama te iskazuju velike varijacije u značajkama među naizgled sličnim slučajevima. Određivanje parametara algoritma statistički utemeljenim testovima implicira dodatnu obradu, čime se smanjuje efikasnost algoritma i oganičava mogućnost primjene. Zbog svega navedenog, vrijednosti upravljačkih parametara zadaća niske razine računalnog vida često su definirane zadatkom. Ove vrijednosti, uključivo pojasnu propusnost h u praksi su najčešće *upravljane znanjem*¹⁵, bilo od strane operatera, ili kontrolirane metodama viših razina obrade.

 $^{^{12}}cross-validation\ methods$

 $^{^{13}}$ plug-in methods

¹⁴pilot estimate

 $^{^{15}}konwledge driven$

3.2.3 Varijabilna pojasna propusnost h = h(x)

Odabir fiksne pojasne propusnosti h, jednake za sve točke $x \in \mathbb{R}^d$, temelji se na pronalaženju vrijednosti koja minimizira srednju grešku aproksimacije funkcije gustoće na cijeloj domeni. Ova vrijednost kompromis je između greške odstupanja (3.15) i varijance (3.16), što je direktna posljedica varijacija u inherentnoj funkciji gustoće ulaznih podataka. Promatranjem izoliranih djelova podatkovne d-dimenzionalne domene sa manjom gustoćom uzoraka može se zaključiti da je odstupanje aproksimacije od stvarne gustoće podataka posljedica relativno udaljenih pojedinačnih uzoraka koji sugeriraju nepostojeće varijacije gustoće, a dominantni uzrok greške aproksimacije u ovim dijelovima domene čini varijanca. Primjena veće vrijednosti pojasne propusnosti h rezultirala bi zaglađenijom aproksimacijom funkcije gustoće koja bolje opisuje stvarne karakteristike ulaznih podataka. S druge strane, u dijelovima prostora sa većom gustoćom uzoraka, dominantni dio greške posljedica je odstupanja. U ovim dijelovima domene, precizniju aproksimaciju inherentne distribucije gustoće uzoraka dobiva se korištenjem manje vrijednosti pojasne propusnosti h čime se otkrivaju fine varijacije u gustoći.

Funkcije gustoće koja bolje odražava karakteristike distribucije podataka moguće je dobiti korištenjem varijabilne pojasne propusnosti h = h(x)čija vrijednost ovisi o lokalnim karakteristikama podataka i samoj gustoći. Varijabilnu pojasnu propusnost h(x) je u jednadžbu (3.6) moguće uključiti na dva načina [5, 6, 44]:

• Estimacija gustoće balonom¹⁶ - Pojasna propusnost definira se kao funkcija točke estimacije $h = h(x), x \in \mathbb{R}^d$. Jednadžba (3.6) prelazi u

$$f_b^D(x) = \frac{1}{Nh(x)^d} \sum_{i=1}^N K\left(\frac{x - x_i}{h(x)}\right)$$
(3.21)

Estimirana gustoća u točki x jednaka je srednjoj vrijednosti jednako skaliranih jezgri centriranih uNulaznih podataka.

• Estimacija gustoće uzorkom¹⁷ - Pojasna propusnost posebno je definirana za svaki uzorak u skupu ulaznih podataka $h = h(x_i), x_i \in \{x_1, ..., x_N\}$, a jednadžba (3.6) prelazi u

$$f_s^D(x) = \frac{1}{N} \sum_{i=1}^N \frac{1}{h(x_i)^d} K\left(\frac{x - x_i}{h(x_i)}\right)$$
(3.22)

U ovom slučaju, estimirana gustoća u točki xodgovara srednjoj vrijednosti različito skaliranih jezgri centriranih uNulaznih podataka.

 $^{^{16}} balloon \ density \ estimation$

¹⁷sample-point estimation

Iako je estimacija gustoće balonom intuitivno jasnija, pokazano je [7, 8] da se superiorni rezultati ostvaruju primjenom tehnike estimacije uzorkom i odabirom vrijednosti parametra $h(x_i)$ obrnuto proporcionalne kvadratnom korijenu $f^D(x_i)$

$$h(x_i) = h_0 \sqrt{\frac{\lambda}{f^D(x_i)}},\tag{3.23}$$

gdje je h_0 fiksna vrijednost pojasne propusnosti, a λ je konstanta proporcionalnosti, koja spektar gustoća dijeli na dva dijela (male i velike gustoće). Dalje, doprinos uzorka x_i se prema (3.21) računa različito skaliranom jezgrom u različitim točkama $x \in \mathbb{R}^d$ pa je teško zadovoljiti uvjet zadan sa (3.3), tj. funkcija jezgre se ne integrira u jedan. S druge strane, estimacijom gustoće uzorkom (3.22) doprinos svakog ulaznog podatka računa se jednako skaliranom jezgrom u svim točkama prostora, a uvjet $\int_{-\infty}^{\infty} K(x) dx = 1$ je zadovoljen.

 \mathbb{R}^{d}

Varijabilna pojasna propusnost $h(x_i)$ je prema (3.23) definirana kao funkcija nepoznate gustoće koju korištenjem jezgre određujemo. Direktna primjena jednadžbe (3.22) nije moguća, a nužan korak za utvrđivanje gustoće je davanje inicijalne estimacije gustoće \tilde{f}^D . Inicijalna procjena gustoće potrebna za određivanje vrijednosti varijabilne pojasne propusnosti može se prema (3.6) dobiti primjenom fiksne pojasne propusnosti $h = h_0$, korištenjem svih ili samo podskupa ulaznih podataka.

Na konačan rezultat značajno utječe odabir konstante proporcionalnosti λ koja podatkovnu domenu efektivno dijeli na područje velikih i malih gustoća. Doprinos uzoraka x_i koji se nalaze u područjima male gustoće sa $\tilde{f}^D(x_i) < \lambda$ skalira se jezgrom veće pojasne propusnosti $h(x_i)$. Doprinos svakog uzorka ima veći doseg, sa manje izraženim lokalnim djelovanjem, što rezultira lokalno zaglađenom funkcijom gustoće i manjim varijacijama. S druge strane, za $\tilde{f}^D(x_i) > \lambda$ doprinos uzorka x_i računa se jezgrom male pojasne propusnosti, sa izraženim lokalnim djelovanjem i malim dosegom. Rezultirajuća funkcija gustoće pod velikim je utjecajem lokalnih uzoraka i otkriva finije varijacije u strukturi podataka. Optimalna vrijednost parametra λ ovisi o problemu i može se odrediti eksperimentalno. Prema [5], dobra vrijednost ovog parametra može se odrediti iz inicijalne aproksimacije gustoće, kao geometrijska sredina gustoća $\left\{\tilde{f}^D(x_i)\right\}_{i=1,\dots,N}$.

3.2.4 Žarišta funkcije gustoće i gravitirajuća područja

Analizom funkcije gustoće mogu se uočiti statističke zakonitosti u distribuciji uzoraka. Područja veće gustoće otkrivaju grupirane podatke, dok područja manje gustoće predstavljaju granicu među skupinama uzoraka različitih karakteristika. Postupak klasteriranja temelji se na određivanju žarišta funkcije gustoće i pripadajućih gravitirajućih područja.

Definicija 4 (Žarište gustoće). Točka $x^* \in \mathbb{R}^d$ je žarište gustoće ako je x^* lokalni maksimum funkcije f^D , tj.

$$\exists \epsilon \in \mathbb{R} : d(x^*, x) < \epsilon \land x \neq x^* \Rightarrow f^D(x) < f^D(x^*) = f_Z^D$$
(3.24)

gdje je $d(x, x^*)$ udaljenost točaka u \mathbb{R}^d .

Kod primjene na stvarne podatke, na rezultirajućoj estimiranoj funkciji mogu postojati područja konstantne gustoće veće od gustoće točaka koje s ovim područjima graniče. U ovom slučaju, žarište nije određeno jednom točkom $x^* \in \mathbb{R}^d$, već skupom točaka koje čine žarišni skup.

Definicija 5 (Žarišni skup). Žarišni skup $Z \subset \mathbb{R}^d$ je skup točaka takav da vrijedi

$$x_1^*, x_2^* \in Z \quad \Rightarrow \quad f^D(x_1^*) = f^D(x_2^*) = f_Z^D$$

$$\exists \epsilon > 0 : d(x, Z) < \epsilon \land x \notin Z \quad \Rightarrow \quad f^D(x) < f_Z^D,$$
(3.25)

gdje je d(x, Z) udaljenost točke x od skupa Z definirana sa

$$d(x, Z) = \min_{x^* \in Z} \{ d(x, x^*) \}$$
(3.26)

Definicija 6 (Gravitirajuće područje). *Gravitirajuće područje žarišta x*^{*} čini skup točaka $x \in \mathbb{R}^d$ za koje procedura penjanja pokrenuta u točki x konvergira prema x^{*}. Gravitirajuće područje žarišnog skupa Z čini skup točaka $x \in \mathbb{R}^d$ za koje procedura penjanja pokrenuta u točki x konvergira prema bilo kojoj točki $x_Z^* \in Z$.

Procedura penjanja¹⁸ [33, poglavlje 4] iz neke točke x prema pripadajućem žarištu gustoće x^* može biti vođena gradijentom funkcije gustoće ili korak po korak¹⁹. Kao posljedica prisustva šuma i nekarakterističnih uzoraka koji se u vektorskom prostoru nalaze na relativno velikoj udaljenosti od matičnih klastera (udaljeni objekti - *outliers*), na estimiranoj funkciji gustoće mogu se pojaviti žarišta ili žarišni skupovi koji ne odražavaju značajne karakteristike podataka. Funkcija gustoće u ovim točkama niža je u odnosu na lokalne maksimume koji predstavljaju veće nakupine struktuiranih podataka.

 $^{^{18}}hill$ -climbing procedure

 $^{^{19}}step$ -wise

Definicija 7 (Značajno žarište). Značajno žarište gustoće Z^* je žarište gustoće $x^* \in \mathbb{R}^d, f^D(x^*) = f_Z^D$ ili žarišni skup $Z \subset \mathbb{R}^d, f^D(x \in Z) = f_Z^D$ ako vrijedi

$$f_Z^D \ge \xi \tag{3.27}$$

 $Vrijednost \xi$ određena je razinom šuma, tj. doprinosom uzoraka približno uniformno raspoređenih u prostoru.

Definicija 8 (Klaster definiran žarištem). Klaster definiran žarištem je podskup $C \subseteq D$ sa točkama $x \in C$ koje pripadaju gravitirajućem području značajnog žarišta Z^* . Točke koje pripadaju gravitirajućem području žarišta Z sa svojstvom

$$f_Z^D < \xi \tag{3.28}$$

smatraju se šumom ili udaljenim objektima.

Lako je uočiti da su za otkrivanje žarišta i gravitirajućih područja značajni relativni odnosi gustoća, a ne apsolutni iznos funkcije, te se efikasnost postupka pronalaženja klastera može povećati izostavljanjem normalizacijskih konstanti kod proračuna funkcije gustoće.

3.2.5 Osjetljivost na šum

Neka je $D = D_C \bigcup D_N$ skup uzoraka u \mathbb{R}^d koji se sastoji od skupa struktuiranih podataka D_C koji formiraju klastere i uniformno distribuiranog šuma D_N . Neka je $X^{(\xi)} = \{x_1^*, ..., x_k^*\}$ uređen skup značajnih žarišta funkcije gustoće f^D skupa uzoraka D definiran sa (h, ξ) , te $X_C^{(0)} = \{\hat{x}_1^*, ..., \hat{x}_k^*\}$ uređen skup značajnih žarišta funkcije gustoće f^{D_C} skupa D_C definiran sa (h, 0). Tada vrijedi:

Lema 1. Broj značajnih žarišta od f^D jednak je broju značajnih žarišta od f^{D_C} , a vjerojatnost da lokacije značajnih žarišta ostaju jednake teži u jedan, ako broj uzoraka šuma $|D_N|$ ide u beskonačno:

$$|X^{(\xi)}| = |X_C^{(0)}|$$
$$\lim_{|D_N| \to \infty} \left[P\left(\sum_{i=1}^{|X^{(\xi)}|} d(x_i^*, \hat{x}_i^*) = 0 \right) \right] = 1$$

Dokaz. Dokaz [18] se temelji na činjenici da je funkcija gustoće uniformnog šuma približno konstanta $f^{D_N} \approx c$, iz čega slijedi

$$\lim_{|D_N|\to\infty} \left(\sup_{y\in\mathbb{R}^d} |c-f^{D_N}(y)| \right) = 0,$$

za bilo koju vrijednost pojasne propusnosti h. Funkcija gustoće skupa podataka Du točki y može se aproksimirati sa

$$f^{D}(y) = f^{D_{C}}(y) + f^{D_{N}}(y) \approx f^{D_{C}}(y) + c,$$

za bilo koji $y \in \mathbb{R}^d$ i dovoljno veliki broj uzoraka $|D_N|$. Gustoća šuma približno je konstanta, a vjerojatnost da skup značajnih žarišta $|X_C^{(\xi)}|$ funkcije gustoće f^D ostane jednak skupu značajnih žarišta $|X_C^{(0)}|$ funkcije gustoće f^{D_C} teži u jedan za $\xi = c$.

Primjer estimacije funkcije gustoće skupa podataka sa i bez prisustva šuma dan je na slici 3.3. Ulaznim podacima (a), dodan je uniformno distribuiran šum (b) u odnosu 1 : 3, tj. struktuirani podaci koji formiraju klastere čine 25% uzoraka. U drugom retku prikazana je nenormalizirana funkcija gustoće estimirana Epanechnikovom jezgrom jezgrom (3.10) za ulazne podatke bez šuma (c) i uz prisustvo šuma (d). Funkcija gustoće zadržava približno isti oblik, a značajni klasteri se ističu iznad razine gustoće definirane doprinosom šuma.U trećem retku prikazani su klasterirani podaci bez šuma (e), i uz prisustvo šuma (f), pri čemu na slici (f) nisu prikazani uzorci klasificirani kao šum. U oba slučaja detektiran je jednak broj klastera $|X| = |X_C| = 4$. Klasteriranjem podataka sa šumom, broj uzoraka pridruženih nekom od klastera $|\tilde{D}_C|$ nešto je veći od stvarnog broja struktuiranih uzoraka $|D_C|$.



(e) Klasterirani podaci

(f) Klasterirani podaci (uzorci klasificirani kao šum nisu prikazani)

Slika 3.3: Klasteriranje estimacijom gustoće: (a) ulazni podaci bez šuma; (b) podaci sa šumom; (c), (d) gustoća estimirana Epanechnikovom jezgrom (bez normalizacije) za podatke sa i bez prisustva šuma; (e), (f) klasterirani podaci sa i bez prisustva šuma.

3.3 Klasteriranje diskretizacijom prostora

Estimirana funkcija gustoće otkriva statističke zakonitosti na nekom skupu podataka, a postupak grupiranja uzoraka u podgrupe temelji se na određivanju žarišta funkcije gustoće i pripadajućih gravitirajućih područja. Ovaj postupak je u metodi srednjeg pomaka [15, 16], koja je uspješno primjenjena na problem segmentacije slike [2, 3, 4, 17], vođen gradijentom estimirane funkcije gustoće. Detalji algoritma segmentacije slike metodom srednjeg pomaka dani su u dodatku A, a osnovna prednost ovog pristupa je mogućnost određivanja žarišta bez potrebe da se izračuna sama funkcija gustoće. Drukčiji pristup uključuje određivanje funkcije gustoće i pokretanje procedure penjanja korak po korak iz više točki prostora, do određivanja svih značajnih žarišta. Ovaj proces može se pojednostavniti aproksimacijom kontinuirane funkcije gustoće diskretnim višedimenzionalnim histogramom [18]. Postupak klasteriranja može se opisati sljedećim koracima:

1. Određivanje granica histograma

Temeljem ulaznih uzoraka određuju se granice d-dimenzionalne hiper-kocke koja definira podatkovnu domenu.

2. Diskretizacija prostora

Domena podataka dijeli se na d-dimenzionalne hiper-kocke dužine brida $\sigma,$ pri čemu je σ parametar.

3. Konstrukcija višedimenzionalnog histograma

Jednostavnim prebrojavanjem uzoraka koji populiraju svaku ćeliju histograma moguće je dobiti diskretnu aproksimaciju kontinuirane funkcije gustoće. Alternativni pristup temelji se na estimaciji gustoće jezgrom, gdje se doprinos svakog uzorka ne računa samo u ćeliji koju uzorak populira već se raspodjeljuje više susjednih ćelija. Doseg doprinosa svakog uzorka ovisi o parametru pojasne propusnosti h, koji se iz praktičnih razloga povezuje sa parametrom diskretizacije σ :

$$h = \rho \sigma, \tag{3.29}$$

gdje je ρ faktor proporcionalnosti. Primjenom pojasne propusnosti koja je višekratnik dimenzija ćelije histograma, jasno je određeno susjedstvo u kojem se računa doprinos svakog ulaznog podataka.

Važno je uočiti da gustoći u nekoj točki $x \in \mathbb{R}^d$ značajnije doprinose samo uzorci u blizini te točke, a funkcija gustoće se može bez veće greške aproksimirati lokalnom funkcijom gustoće $\hat{f}^D(x)$:

$$\hat{f}^D(x) = \frac{1}{Nh^d} \sum_{x_l \in okolina(x)} K\left(\frac{x - x_l}{h}\right), \qquad (3.30)$$

gdje je okolina(x) skup definiran sa

$$okolina(x) = \{x_l : d(x_l, x) \le \sigma_{okolina}\}$$

$$(3.31)$$

$$\sigma_{okolina} = \tau \sigma \tag{3.32}$$

Faktor proporcionalnosti τ može, ali i ne mora biti jednak faktoru proporcionalnosti ρ . Primjenom faktora proporcionalnosti $\tau = \rho$ i Epanechnikove jezgre (3.10), u kojem slučaju doprinos uzorka iščezava za $d(x, x_i) > h$, vrijedi $\hat{f}^D(x) = f^D(x)$.

Kvaliteta estimata može se povećati primjenom varijabilne pojasne propusnosti, tehnikom estimacije gustoće uzorkom (3.22), adaptivnom lokalnom funkcijom gustoće:

$$\hat{f}^D(x) = \frac{1}{N} \sum_{x_l \in okolina(x)} \frac{1}{h(x_l)^d} K\left(\frac{x - x_l}{h(x_l)}\right)$$
(3.33)

Pojasna propusnost $h(x_i)$ za računanje doprinosa uzorka x_i zadana je sa

$$h(x_i) = h_0 \sqrt{\frac{\lambda}{\tilde{f}^D(x_i)}},\tag{3.34}$$

gdje je $h_0 = \rho \sigma$ fiksna pojasna propusnost, \tilde{f}_D inicijalna procjena gustoće te λ konstanta proporcionalnosti. Inicijalna procjena gustoće \tilde{f}^D može se dobiti jednostavnim prebrojavanjem uzoraka koji populiraju svaku ćeliju histograma. Konstanta proporcionalnosti λ jednaka je geometrijskoj sredini inicijalne procjene gustoće \tilde{f}^D , a može se računati kao geometrijska sredina gustoća $\left\{\tilde{f}^D(x_i)\right\}_{i=1,\dots,N}$ ili geometrijska sredina gustoća svih populiranih ćelija histograma. Faktor proporcionalnosti $\tau(x_i)$ koji definira okolinu u kojoj se računa doprinos uzorka x_i zadan je sa

$$\tau(x_i) = \tau_0 \sqrt{\frac{\lambda}{\tilde{f}^D(x_i)}} \tag{3.35}$$

$$\sigma_{okolina}^{(i)} = \tau(x_i)\sigma \tag{3.36}$$

gdje je τ_0 fiksna vrijednost faktora proporcionalnosti τ .

4. Otkrivanje žarišta i gravitirajućih područja

Procedura penjanja pokreće se iz ćelija histograma sa pozitivnom podrškom, tj. estimiranom gustoćom $\hat{f}^D > 0$. Procedura je vođena korak po korak, na način da se nastavlja na susjednu ćeliju sa najvišom podrškom (najvišom funkcijom gustoće). Procedura penjanja se zaustavlja ukoliko je trenutna ćelija lokalni maksimum (žarište gustoće (3.24)), ili ukoliko je trenutna ćelija već pridružena lokalnom maksimumu, tj. nalazi se na putanji ranije pokrenute procedure penjanja.

Moguća je situacija u kojoj sve ćelije koje okružuju trenutnu ćeliju imaju jednaku podršku. U ovom slučaju, procedura se nastavlja na susjedne ćelije sa jednakom podrškom uz pamćenje putanje (zbog izbjegavanja petlji), do pronalaska ćelije sa većom podrškom. Ukoliko takva ne postoji, skup ćelija sa jednakom podrškom predstavlja žarišni skup (3.25).

5. Klasteriranje

Pokretanjem procedure penjanja iz svih ćelija sa pozitivnom podrškom podatkovna domena podijeljena je na disjunktna gravitirajuća područja određena žarištem ili žarišnim skupom. Ulazni podaci klasificiraju se prema pripadnosti gravitirajućem području, pri čemu se uzorci koji pripadaju gravitirajućem području sa funkcijom gustoće u žarištu manjom od razine šuma (3.28) smatraju šumom ili udaljenim objektima.

Razina šuma ξ može biti zadana kao parametar ili se određivati adaptivno iz podataka. U predloženom algoritmu segmentacije slike primijenjen je pristup adaptivnog računanja razine šuma. Razina šuma ξ povezana sa geometrijskom sredinom Λ estimirane funkcije gustoće $f^D(x)$ te vrijedi

$$\xi = \varepsilon \Lambda, \tag{3.37}$$

gdje je ε faktor proporcionalnosti. Važno je uočiti da geometrijska sredina A razlikuje od konstante proporcionalnosti λ koja se koristi za računanje varijabilne pojasne propusnosti, a predstavlja geometrijsku sredinu inicijalne procjene gustoće $\tilde{f}^D(x)$.

3.4 Segmentacija slike diskretizacijom prostora

Usprkos razmjerno velikom broju predloženih metoda, segmentacija slike i dalje predstavlja jedan od temeljnih problema računalnog vida. Segmentacija slike je u svojoj naravi proces niske razine koji reducira obim vizualne informacije sadržane u promatranoj sceni, a podjela slike na regije kao produkt ovog procesa korisna je ulazna informacija za brojne postupke obrade više razine, kao dio kompleksnih sustava računalnog vida. I dok su u literaturi predložena rješenja primjenom kojih je ostvaren napredak u kvaliteti dobivenih segmentacija, računalna složenost i problem obrade slike visoke rezolucije (veliki broj piksela) i dalje ograničava mogućnost primjene. Ovo naročito vrijedi za sustave od kojih se očekuje obrada u stvarnom vremenu, na brzinama video prijenosa. Po mišljenju autora, algoritam segmentacije najniže razine primjenjiv u sustavima koji rade u stvarnom vremenu trebao bi zadovoljavati sljedeće uvjete:

- *Točnost* Uočavanje svih lokalnih, perceptualno značajnih homogenih regija koje odražavaju globalne osobine scene.
- *Efikasnost* Brzina obrade trebala bi se približiti efikasnosti drugih procesa niske razine, kao što je na primjer detekcija rubova. Ovo implicira složenost linearnu broju piksela slike, kao i razmjerno malu memorijsku složenost.
- *Minimalni zahtjevi za poznavanje domene* Mala osjetljivost na izbor ulaznih parametara, a sami upravljački parametri algoritma moraju biti intu-

itivno jasni. Mala osjetljivost osigurava stabilnost rezultata i zadržavanje razine kvalitete unutar prihvaćenih granica, dok se jednostavnim parametrima omogućava upravljanje procesom segmentacije povratnom vezom iz viših razina obrade, ili od strane operatera.

• Analiza temeljena na grupiranim istovrsnim značajkama - Algoritam segmentacije mora se temeljiti na jasno određenoj skupini homogenih značajki. Sinergijom rezultata temeljenih na raznovrsnim značajkama u višim razinama obrade moguće je odrediti značajke sa većim informacijskim sadržajem i povratnom vezom optimirati procese niže razine.

U ostatku poglavlja opisana je metoda adaptivne segmentacije slike mrežom diskretnih elemenata AMBIS. Ova metoda temelji se na pretpostavci da funkciji gustoće u nekoj točki prostora značajnije doprinose samo objekti u neposrednoj blizini te točke. Funkcija gustoće računa se tehnikom estimacije gustoće uzorkom (3.22), adaptivnom jezgrom čija se pojasna propusnost određuje heuristički prema jednadžbi (3.23), temeljem ulaznih podataka. Upotrebom adaptivne jezgre povećana je stabilnost algoritma s obzirom na odabir upravljačkih parametara, uz kvalitetnije uočavanje lokalnih pojava. Segmentacija je temeljena na korištenju informacije o boji svakog piksela ulazne slike, a složenost algoritma linearna je broju piksela.

3.4.1 Prostorna domena i domena boja

Tipičan način zapisa digitalne slike podrazumijeva 2-dimenzionalnu rešetku piksela slike predstavljenih *p*-dimenzionalnim vektorima. Dimenzija *p* ovisi o formatu zapisa te vrijedi p = 1 za sliku sivih nijansi, p = 3 za sliku u boji, ili p > 3 za multispektralne slike. Koordinatna rešetka piksela definira prostornu domenu, dok *p*-dimenzionalni vektori piksela određuju domenu boja. Povezivanjem prostorne domene i domene boja, rezultirajuća vizualna informacija kodirana je u p + 2-dimenzionalni prostor.

Algoritme segmentacije slike moguće je prema načinu djelovanja podijeliti na metode bazirane na prostornoj domeni i metode bazirane na domeni boja. Pored algoritama koji pripadaju jednoj ili drugoj skupini, postoje algoritmi koji rade direktno na združenoj domeni slike. Algoritam segmentacije temeljen na metodi *srednjeg pomaka* [2, 3, 4, 17] izložen u dodatku A, pod pretpostavkom euklidske metrike obje domene, koristi multivarijabilnu jezgru definiranu produktom dviju radijalno simetričnih jezgri sa zasebnim parametrom pojasne propusnosti za svaku od domena:

$$K_{h_s,h_r}(x) = \frac{C}{h_s^2 h_r^p} k\left(\left\| \frac{x^{(s)}}{h_s} \right\|^2 \right) k\left(\left\| \frac{x^{(r)}}{h_r} \right\|^2 \right),$$
(3.38)

gdje je $x^{(s)}$ prostorni, a $x^{(r)}$ spektralni dio vektora x i predstavlja koordinate u prostoru boja, k(x) profil jezgre koja se koristi u obje domene, h_s i h_r pripadajuće

pojasne propusnosti u svakoj od domena, te C normalizacijska konstanta. Euklidska metrika združene domene ostvaruje se odnosom parametara h_s i h_r , koji određuju doseg utjecaja jezgre i skalu opservacije u svakoj od domena. Osnovni problem kod ovog pristupa je osjetljivost na izbor parametara h_s i h_r [73]. Pored ovog, primjenom algoritma u združenoj domeni, povećava se dimenzionalnost ulaznih podataka (d = 5 za slike u boji) što rezultira većom računalnom složenošću algoritma i dužem vremenu obrade.

Sa ciljem postizanja optimalnog odnosa kvalitete rezultata i efikasnosti, metoda segmentacije slike diskretizacijom prostora, predložena u ovoj disertaciji, proces obrade razdvaja u dva osnovna koraka. Prvi korak uključuje filtriranje ulaznih podataka diskretizacijom domene boja, nakon čega se filtrirani podaci reduciranog informacijskog sadržaja klasteriraju u prostornoj domeni. Razdvajanjem obrade u prostornoj domeni i domeni boja smanjena je osjetljivost algoritma na izbor ulaznih parametara uz mogućnost zasebnog zadavanja skale opservacije za svakoj od domena.

Metode grupiranja u vektorskom prostoru polaze od pretpostavke uniformnosti prostora, prema čemu bi perceptualne razlike u poimanju boja trebale približno odgovarati euklidskim udaljenostima vektora kojima su boje u odabranom prostoru predstavljene. Ovaj uvjet nije zadovoljen za RGB format zapisa boje, koji je najčešće zastupljen kod sklopovlja za dobavu vizualnih informacija. Najbolja aproksimacija perceptualno uniformnog prostora postignuta je $L^*u^*v^*$ i $L^*a^*b^*$ prostorima boja [35, poglavlje 3], koji se razlikuju u reprezentaciji kromatskih koordinata, dok L^* komponenta u oba slučaja predstavlja svjetlinu. $L^*u^*v^*$ i $L^*a^*b^*$ prostori boja su sa RGB vrijednostima povezani nelinearnim transformacijama danim u tablici 2.1.

Sira diskusija o percepciji boje i udaljenostima u prostoru boja dana je u poglavlju 2.1. Algoritam AMBIS opisan u ostatku poglavlja implementiran je u $L^*u^*v^*$ prostoru boja. Kako je sam postupak segmentacije nezavisan od primijenjene transformacije boja, algoritam je moguće primijeniti i u drugim prostorima boja. U poglavlju 5.1 dani su rezultati evaluacije opisanog algoritma segmentacije implementiranog u $L^*u^*v^*$ prostoru boja. Usporedba kvalitete rezultata dobivenih algoritmom implementiranim u $L^*u^*v^*$ prostoru boja u odnosu na rezultate dobivene primjenom algoritma u primarnom RGB prostoru dana je u poglavlju 5.3.

3.4.2 Diskretna aproksimacija gustoće u domeni boja

Ovaj postupak temelji se na proceduri klasteriranja diskretizacijom prostora opisanom u poglavlju 3.3, a za cilj ima određivanje dominantnih boja i pripadajućih gravitirajućih područja te pridruživanje svakog piksela slike jednoj od dominantnih boja. Pikseli slike predstavljeni su vektorima u 3-dimenzionalnom $L^*u^*v^*$ prostoru, a dominantne boje mogu se odrediti lociranjem žarišta funkcije gustoće aproksimirane diskretnim višedimenzionalnim histogramom. Funkcija gustoće računa se tehnikom estimacije gustoće uzorkom (3.22), Epanechnikovom jezgrom varijabilne pojasne propusnosti (3.23).

Primjenom Epanechnikove jezgre, prema (3.10) doprinos uzorka x_i iščezava za $d(x, x_i) > h$. Odabirom upravljačkih parametara $\rho = \tau$ (jednadžbe (3.29), (3.32)) lokalna funkcija gustoće (3.30) postaje jednaka estimiranoj funkciji gustoće danoj sa (3.1). Za jezgru varijabilne pojasne propusnosti, pojasna propusnost $h(x_i)$ (3.34) i faktor proporcionalnost $\tau(x_i)$ (3.35) računaju se adaptivno za svaki piksel slike, uz $\rho = \tau_0$. U poglavlju 5.4 prezentirani su rezultati eksperimenta u kojem je ispitan utjecaj funkcije jezgre na učinkovitost algoritma segmentacije. Uspoređene su segmentacije dobivene primjenom Epanechnikove (3.10) i Normalne (3.12) jezgre, a rezultati eksperimenta u skladu su sa pretpostavkom da odabir jezgre nema većeg utjecaja na estimiranu funkciju gustoće [26] i kvalitetu dobivenih segmentacija.

Postupak estimacije funkcije gustoće adaptivnom jezgrom i diskretizacijom prostora prikazan je algoritmom 1. Ulazne vrijednosti algoritma uključuju:

- Podaci: ulazna slika imgRGB, broj piksela slike N
- Upravljački parametri: fiksna pojasna propusnost $h_r^{(0)}$, faktor proporcionalnosti ρ (koristi se za određivanje dimenzija ćelije histograma), jezgra K(x)

Rezultat izvršavanja algoritma je nenormalizirana estimirana diskretna funkcija gustoće i parametri diskretizacije. Estimirana funkcija gustoće pohranjena je u obliku histograma u varijabli hist. Parametri diskretizacije, u obliku broja diskretnih ćelija po svakoj komponenti boje, pohranjeni su u varijabli nbins.

Postupak određivanja diskretne aproksimacije funkcije gustoće tehnikom adaptivne jezgre, dan algoritmom 1 opisan je sljedećim koracima:

1. Transformacija domene boja

Algoritam segmentacije nije direktno povezan sa bilo kojim prostorom značajki i moguće ga je implementirati u proizvoljnoj domeni. U većini eksperimenata u ovom radu korišten je algoritam implementiran u $L^*u^*v^*$ prostoru, tj. RGB koordinate piksela ulazne slike transformirane su u koordinate $L^*u^*v^*$ prostora boja. Zamjenom transformacije, algoritam se jednostavno implementira u bilo kojoj drugoj domeni boja. Transformacije prostora boja dane su u tablici 2.1.

2. Određivanje granica histograma

Određuje se minimalna i maksimalna vrijednost ulaznih 3-dimenzionalnih podataka, za svaku dimenziju zasebno. Ovaj postupak provodi se neovisno

```
 \textbf{Algoritam 1} \quad \texttt{hist, nbins} \leftarrow \textbf{diskretna\_gustoća(imgRGB, N, h_r^{(0)}, \rho, K(x)) }
```

Ulaz: slika imgRGB, broj piksela N, fiksna pojasna propusnost $h_r^{(0)}$, faktor proporcionalnosti ρ , funkcija jezgre K(x)

Izlaz: diskretna aproksimacija gustoće hist, broj ćelija u svakoj dimenziji nbins

%% Konverzija domene i diskretizacija prostora 1: $imgTRAN \leftarrow transformacija_boje(imgRGB) \%\%$ Tablica 2.1 2: $min[1:3], max[1:3] \leftarrow odredi_interval(imgTRAN)$ 3: $\sigma = h_r^{(0)} / \rho$ 4: $nbins[1:3] \leftarrow (max[1:3] - min[1:3])/\sigma$ %% Inicijalna estimacija funkcije gustoće prebrojavanjem 5: $chist(nbins[1] \cdot nbins[2] \cdot nbins[3]) \leftarrow 0$ 6: for i = 1 : N do $pbin[1:3] \leftarrow (imgTRAN[i,1:3] - min[i,1:3])/\sigma$ 7: chist[pbin] = chist[pbin] + 18: 9: end for %% Konstanta proporcionalnosti λ 10: n = 011: s = 012: for all chist[i] > 0 do $s = s + \ln(chist[i])$ 13:n = n + 114: 15: **end for** %% Geometrijska sredina populiranih ćelija 16: $\lambda = \exp(s/n)$ %% Estimacija funkcije gustoće adaptivnom jezgrom 17: $hist(nbins[1] \cdot nbins[1] \cdot nbins[2]) \leftarrow 0$ 18: for all chist[l] > 0 do $h_r = h_r^{(0)} \cdot \sqrt{\lambda/chist[l]}$ 19: $\tau = \rho \cdot \sqrt{\lambda / chist[l]}$ 20: $c_l \leftarrow \mathbf{koordinate_centra}(chist[l])$ 21: for all hist[u]: $c_u \leftarrow \text{koordinate_centra}(\text{hist}[u]), \ d(c_u, c_l) \leq \tau \sigma \text{ do}$ 22: $\hat{Z}(c_u, c_l) = chist[l] \cdot K\left(\frac{c_u - c_v}{h_r}\right) / h_r^3 \qquad \%\% \text{ Doprinos prema (3.42)}$ 23: $hist[u] = hist[u] + Z(c_u, c_l)$ 24:end for 25:26: end for 27: return hist, nbins

o primijenjenoj transformaciji prostora boja, čime se algoritam automatski prilagođava ulaznim podacima. Zbog prirode problema računalnog vida, kod kojeg su ulazni podaci u pravilu grupirani u manjem dijelu podatkovne domene boja, sa velikim varijacijama od slučaja do slučaja, adaptivno određivanje granica histograma može značajno smanjiti memorijske zahtjeve algoritma. Postupak određivanja granica domene boja zahtjeva prolaz kroz sve podatke (složenost O(N)), a pronađene granice pohranjene su u varijablama min i max, za svaku koordinatu boje zasebno.

3. - 4. Diskretizacija prostora značajki

Dužina brida ćelije histograma povezana je sa pojasnom propusnosti i vrijedi

$$\sigma = \frac{h_r^{(0)}}{\rho},\tag{3.39}$$

gdje je $h_r^{(0)}$ fiksna pojasna propusnost u domeni boja te ρ faktor proporcionalnosti. Domena podataka (prostor boja) dijeli se na ćelije (kocke) dužine brida σ zadanog sa (3.39). Broj ćelija histograma po svakoj dimenziji pohranjen je u varijablu **nbins**, a ukupan broj ćelija histograma jednak je umnošku broja ćelija po svakoj komponenti boje.

5. - 9. Procjena gustoće prebrojavanjem uzoraka

Inicijalna procjena gustoće \tilde{f}^D dobija se prebrojavanjem piksela slike koji populiraju svaku ćeliju histograma. Za svaki piksel slike računaju se koordinate pripadajuće ćelije histograma, a iznos gustoće ćelije inkrementira se za jedan. Ovako izračunata, procjena gustoće predstavlja nenormaliziranu gustoću, tj. broj uzoraka u svakoj ćeliji histograma ne dijeli se sa normalizacijskom konstantom. Ovaj postupak zahtjeva prolaz kroz sve piksele slike (složenost O(N)), a rezultirajuća diskretna inicijalna procjena gustoće pohranjena je u obliku histograma u varijabli *chist*.

10. - 16. Određivanje konstante proporcionalnosti

Konstanta proporcionalnosti λ određuje se iz inicijalne procjene gustoće, a računa se kao geometrijska sredina inicijalne gustoće svih populiranih ćelija histograma. Složenost ovog koraka je O(M), gdje je M broj populiranih ćelija histograma, tj. ćelija sa $\tilde{f}^D > 0$.

17. - 26. Proračun adaptivne lokalne funkcije gustoće

Prema (3.33), doprinos svakog piksela slike x_i računa se jezgrom varijabilne pojasne propusnosti (3.34) u adaptivnoj okolini (3.36). Efikasnost ovog postupka može se povećati korištenjem inicijalne procjene gustoće \tilde{f}^D . Neka je

$$Z(x,x_j) = \frac{1}{h(x_j)^3} K\left(\frac{x-x_j}{h(x_j)}\right)$$
(3.40)

doprinos piksela x_j u točki x. Uvrštavanjem (3.40) u (3.33), adaptivnu lokalnu funkciju gustoće možemo zapisati kao

$$\hat{f}^D(x) = \frac{1}{N} \sum_{x_l \in okolina(x)} Z(x, x_l), \qquad (3.41)$$

gdje je $x_l \in okolina(x)$ ako vrijedi $d(x, x_l) \leq \tau(x_l)\sigma$, a $\tau(x_l)$ zadan sa (3.35). Neka je c_u koordinata centra *u*-te ćelije histograma. Doprinos svih piksela koji populiraju *v*-tu ćeliju histograma estimiranoj funkciji gustoće u središtu *u*-te ćelije približno je jednak

$$Z(c_u, c_v) \approx \hat{Z}(c_u, c_v) = \tilde{f}^D(c_v) \frac{1}{h(c_v)^3} K\left(\frac{c_u - c_v}{h(c_v)}\right)$$
(3.42)

Doprinos svih piksela koji populiraju v-tu ćeliju histograma je u (3.42) uračunat na način da je boja svakog piksela zamijenjena koordinatama središta ćelije histograma u domeni boja koju piksel populira. Doprinos adaptivno skalirane jezgre sa ishodištem u centru ćelije histograma pomnožen je sa brojem piksela koji ćeliju populiraju, tj. inicijalnom procjenom gustoće prebrojavanjem \tilde{f}^D . Uvrštavanjem (3.42) u (3.41) dobija se

$$\hat{f}^D(c_u) \approx \frac{1}{N} \sum_{c_l: d(c_u, c_l) \le \tau(c_l)\sigma} \hat{Z}(c_u, c_l), \qquad (3.43)$$

gdje je $\hat{f}^{D}(c_u)$ gustoća na *u*-toj ćeliji histograma. Za estimaciju funkcije gustoće koja otkriva statističke zakonitosti u ulaznim podacima, broj populiranih ćelija histograma mali je u odnosu na broj ulaznih podataka. Korištenjem aproksimacije uvedene sa (3.42), koja efektivno sve piksele slike premješta u centar pripadajuće ćelije, iskorištava se inicijalna procjena gustoće te se doprinos svih podataka jedne ćelije histograma računa u jednom prolazu.

Algoritam 1 pristupa svim populiranim ćelijama sa inicijalnom procjenom gustoće većom od nula (najmanje jedan uzorak u ćeliji). Za svaku populiranu ćeliju računa se adaptivna pojasna propusnost i okolina, nakon čega se doprinos uračunava u ćelijama koje zadovoljavaju uvjet adaptivne okoline. Pošto su za postupak klasteriranja bitni relativni odnosi, a ne apsolutni iznos gustoće, rezultirajuća diskretna funkcija gustoće se ne normalizira, a konačni rezultat pohranjen je u obliku diskretnog histograma u varijabli hist. Ovaj postupak uključuje pristup svim populiranim ćelijama histograma, tj. ćelijama sa inicijalnom procjenom gustoće $\tilde{f}^D > 0$ (složenost O(cM), gdje je M broj ćelija histograma sa $\tilde{f}^D > 0$ te a c konstanta određena okolinom u kojoj se računa doprinos).

Algoritam 2 oznake \leftarrow otkrivanje_klastera(hist, nbins, ε)

```
Ulaz: diskretna aproksimacija gustoće hist, parametri diskretizacije nbins, relativna razina šuma ε
Izlaz: skup oznaka pripadnosti oznake
%% Apsolutna razina šuma ξ
1: n = 0
```

```
2: s = 0
 3: for all hist[i] > 0 do
      s = s + \ln(hist[i])
 4:
      n = n + 1
 5:
 6: end for
 7: \Lambda = \exp(s/n)
                     %% Geometrijska sredina ćelija sa pozitivnom podrškom
 8: \xi = \varepsilon \Lambda
                      \%\% Adaptivna razina šuma (3.37)
    %% Otkrivanje žarišta rekurzivnom procedurom penjanja
9: oznaka = 1
10: oznake(nbins[1] \cdot nbins[1] \cdot nbins[2]) \leftarrow -1
11: for all hist[i] > 0 and oznake[i] = -1 do
      oznake[i] \leftarrow rekurzivno_penjanje(oznake, hist, nbins, i, oznaka, \xi)
12:
      if oznake[i] = oznaka then %% Otkriveno je značajno žarište
13:
        oznaka = oznaka + 1
14 \cdot
      end if
15:
16: end for
```

```
17: return oznake
```

3.4.3 Otkrivanje žarišta i gravitirajućih područja

Rezultat izvođenja algoritma 1 je diskretna aproksimacija funkcije gustoće piksela slike u domeni boja. Sljedeći korak temelji se na otkrivanju značajnih žarišta funkcije gustoće i pripadajućih gravitirajućih područja čime su određeni klasteri domene boja. Postupak otkrivanja žarišta funkcije gustoće prikazan je algoritmom 2. Ulazne vrijednosti algoritma se:

- **Podaci:** diskretna aproksimacija funkcije gustoće hist, broj diskretnih ćelija po svakoj komponenti boje nbins
- Upravljački parametri: relativna razina šuma ε , temeljem koje se određuje apsolutna razina šuma prema (3.37)

Rezultat izvršavanja algoritma je skup oznaka pripadnosti **oznake** koji određuje pripadnost svake ćelije diskretnog histograma sa pozitivnom podrškom $\hat{f}^D > 0$ klasteru domene boja. Ćelijama koje pripadaju gravitirajućem području žarišta gustoće niže od razine šuma smatraju se šumom, te im se pridružuje oznaka pripadnosti 0.

```
Algoritam 3 oznake[i] \leftarrow rekurzivno_penjanje(oznake, hist, nbins, i,...
oznaka, \xi)
```

Ulaz: oznake pripadnosti oznake, diskretna aproksimacija gustoće hist, indeks ćelije i, nova oznaka pripadnosti oznaka, apsolutna razina šuma ξ

Izlaz: pridružena oznake pripadnosti i-te ćelije oznake[i]

%% Zaustavljanje procedure ukoliko je ćelija već pridružena žarištu

```
1: if oznake[i] \ge 0 and oznake[i] < oznaka then
     return oznake[i]
 2:
 3: end if
   %% Ćeliji se pridružuje oznaka pripadnosti oznaka
 4: oznake[i] = oznaka
   %% Određivanje sljedećeg koraka procedure penjanja
 5: next_i = sljedeci_korak(hist, oznake, nbins, i)
   %% Nastavak procedure penjanja u ovisnosti o sljedećem koraku
 6: if next_i = i then %% pronađeno je žarište
     if hist[i] > \xi then
 7:
        oznake[i] = oznaka
 8:
                               %% Značajno žarište
 9:
     else
                               %% Šum
10:
        oznake[i] = 0
11:
     end if
12: else
     oznake[i] \leftarrow rekurzivno_penjanje(oznake, hist, nbins, next_i, oznaka, \xi)
13:
14: end if
15: return oznake[i]
```

Postupak otkrivanja značajnih žarišta i gravitirajućih područja opisan je sljedećim koracima:

1. - 8. Apsolutna razina šuma

Apsolutna razina šuma određuje se prema (3.37) temeljem relativne razine šuma ε i geometrijske sredine ćelija sa pozitivnom podrškom $\hat{f}^D > 0$. Složenost ovog koraka je $O(\delta M)$, gdje je M broj populiranih ćelija histograma, a koeficijent δ uračunava utjecaj jezgre na rubovima populiranih područja domene boja, gdje se doprinos računa i u ćelijama koje s ovim područjima graniče.

9. - 17. Otkrivanje žarišta procedurom penjanja "korak po korak"

Pripadnost gravitirajućem području potrebno je odrediti za sve populirane ćelije histograma, tj. ćelije sa pozitivnom podrškom (stvarni broj ćelija sa pozitivnom podrškom nešto je veći u odnosu na broj populiranih ćelija histograma zbog računanja doprinosa uzoraka jezgrom na granici populiranog područja domene). Prije pokretanja procedure penjanja, oznake pripadnosti svih ćelija inicijaliziraju se na negativnu vrijednost, a procedura se pokreće samo za populirane ćelije koje nisu već pridružene gravitirajućem području (imaju negativnu oznaku pripadnosti). Postupak pronalaženja žarišta vođen je "korak po korak", na način da se procedura penjanja u svakom koraku nastavlja na susjednu diskretnu ćeliju sa najvišom podrškom. Oznake pripadnosti pridjeljuju se počevši sa oznakom pripadnosti 1. Ukoliko je otkriveno žarište značajno (definicija 7), ćelijama klastera definiranog žarištem (definicija 8) pridjeljuje se dana oznaka pripadnosti, a sljedeća oznaka se inkrementira za jedan. U suprotnom, ćelijama gravitirajućeg područja pridjeljuje se oznaka pripadnosti 0, tj. proglašavaju se šumom. Procedura penjanja temelji se na rekurzivnom postupku prikazanim algoritmom 3.

Ulazne vrijednosti rekurzivnog algoritma penjanja su sljedeće:

- **Podaci:** oznake pripadnosti **oznake**, diskretna aproksimacija funkcije gustoće hist, parametre diskretizacije nbins, indeks ćelije histograma *i*, sljedeća slobodna oznaka pripadnosti *oznaka*
- Upravljački parametri: apsolutni prag šuma ξ

Algoritam se zaustavlja kada procedura penjanja otkrije žarište gustoće ili ćeliju koja je na putanji ranije pokrenute procedure penjanja. Svim ćelijama na putanji procedure penjanja pridružuje se oznaka pripadnosti koja ovisi o načinu zaustavljanja algoritma.

Rekurzivna procedura penjanja sastoji se od sljedećih koraka:

1. - 3. Provjera oznake pripadnosti ćelije

Ukoliko algoritam u proceduri penjanja naiđe na ćeliju kojoj je već pridružena nenegativna oznaka pripadnost, a da se ta oznaka razlikuje od oznake *oznaka* koja je privremeno pridružena svim ćelijama na putanji trenutne procedure penjanja, algoritam se zaustavlja. U ovom slučaju, otkrivena je ćelija koja se nalazi na putanji ranije pokrenute procedure penjanja, a daljnji uspon iz ove točke vodi prema već otkrivenom žarištu, ili ga otkrivena ćelija sama predstavlja. Svim ćelijama koje se nalaze na putanji trenutne procedure penjanja unatrag se pridjeljuje oznaka pripadnosti otkrivene ćelije.

4. Pridruživanje privremene oznake pripadnosti

Svim ćelijama na putanji trenutne procedure penjanja privremeno se pridružuje oznaka pripadnosti *oznaka*. Na ovaj način izbjegavaju se zatvorene petlje do kojih može doći u slučaju pretraživanja područja jednake gustoće funkcijom **sljedeci_korak**

5. Određivanje sljedećeg koraka procedure

Funkcija sljedeci_korak uspoređuje funkciju gustoće na *i*-toj ćeliji i ćelijama koje *i*-tu ćeliju okružuju. Varijabla *next_i* određuje ćeliju sa najvišom podrškom (najvišom funkcijom gustoće), tj. sljedeći korak procedure penjanja. U slučaju nailaska na područje jednake gustoće, ova funkcija ispituje mogućnost nastavka procedure penjanja na ćelije jednake gustoće kojima nije pridružena oznaka *oznaka*, koja se pridružuje svim ćelijama na putanji trenutne procedure penjanja. Povratna vrijednost funkcije može biti jednaka trenutnom indeksu ćelije, u kojem slučaju ne postoji mogućnost nastavka procedure penjanja, tj. trenutna ćelija je žarište ili predstavnik žarišnog skupa.

6. - 14. Nastavak procedure penjanja

Ukoliko vrijedi $next_i = i$, procedura penjanja je završena, a otkrivena ćelija je žarište ili predstavnik žarišnog skupa. Ćeliji se pridružuje oznaka pripadnosti oznaka samo ako je funkcija gustoće na ćeliji viša ili jednaka od apsolutne razine šuma ξ . U suprotnom, ćeliji se pridružuje oznaka pripadnosti 0 (šum). Pridružena oznaka pripadnosti rekurzivno se unatrag pridružuje svim ćelijama na putanji završene procedure penjanja.

Ukoliko je sljedeći korak različit od trenutnog indeksa ćelije, procedura penjanja se nastavlja na ćeliju sa indeksom *next_i*.

Postupak otkrivanja značajnih žarišta i gravitirajućih područja opisan algoritmom 2 i algoritmom 3 pristupa svim ćelijama diskretne aproksimacije gustoće za koje vrijedi $\hat{f}^D > 0$, tj. svim ćelijama sa pozitivnom podrškom. Pri tom se ćelijama pristupa kod određivanja apsolutne razine šuma i ponovo u proceduri penjanja. Broj ovih ćelija nešto je veći od broja populiranih ćelija sa pozitivnom inicijalnom procjenom gustoće $\tilde{f}^D > 0$, tj. ćelija koje populira najmanje jedan piksel ulazne slike. Ovi iznosi se razlikuju zbog uzoraka na rubnim populiranim područjima, čiji se doprinos jezgrom računa i u ćelijama koje s ovim područjima graniče. Složenost postupka rekurzivnog pridruživanja oznaka je $O(2\delta M)$, gdje je M broj populiranih ćelija histograma, a koeficijent δ uračunava utjecaj jezgre na rubovima populiranih područja domene boja.

3.4.4 Preslikavanje u prostornu domenu slike

Posljednji korak filtriranja sastoji se od jednostavnog preslikavanja otkrivenih klastera domene boja u prostornu domenu slike. Ovaj postupak temelji se na proceduri izrastanja područja koja se pokreće iz više točaka slike, a nastavlja se dok susjedni pikseli slike odgovaraju istom klasteru domene boja. Broj segmenata rezultirajuće inicijalne segmentacije slike veći je ili jednak broju klastera domene boja. Veći broj segmenata slike u odnosu na broj klastera domene boja nastaje kao posljedica činjenice da nakupine piksela u domeni boja mogu odgovarati prostorno udaljenim i nepovezanim objektima na slici. U ovom slučaju, prilikom preslikavanja klastera domene boja u prostornu domenu, svakom od nepovezanih segmenata koji odgovaraju istom klasteru u domeni boja pridružuje se zasebna oznaka pripadnosti segmentu u domeni slike. Ovisno o primjeni, u nekim slučajevima poželjno je svim objektima sličnih karakteristika pridružiti istu oznaku pripadnosti u domeni slike, čak i ako su ovi prostorno nepovezani.

3.4.5 Segmentacija filtrirane slike u prostornoj domeni

Opisanim postupkom filtriranja slike u dobiva se segmentacija kod koje je broj segmenata veći ili jednak broju otkrivenih klastera domene boja. Filtriranje efektivno reducira informacijski sadržaj slike smanjenjem varijacija boje, zamjenom boje svakog piksela ulazne slike dominantnom bojom pripadajućeg klastera domene boja. Na ovako filtriranu sliku može se dodatno primijeniti neka od metoda segmentacije slike u prostornoj domeni. U ovom slučaju, kao ulazni podaci se umjesto pojedinačnih piksela slike koriste segmenti dobiveni filtriranjem u domeni boja, čime se reducira broj uzoraka i povećava efikasnost metode segmentacije. Klasteriranjem u prostornoj domeni inicijalni segmenti povezuju se u veće skupine, pa je broj segmenata konačne segmentacije uvijek manji ili jednak broju segmenata dobivenih filtriranjem u domeni boja. Broj segmenata ostaje isti samo u slučaju kada algoritam klasteriranja u prostornoj domeni svaki od inicijalnih segmenata prepozna kao zaseban klaster. Primjenom ovog koraka konačni rezultat temelji se na kombinaciji spektralnih i prostornih varijacija u ulaznoj slici. Kako je broj inicijalnih segmenata uvijek značajno manji od broja piksela ulazne slike, za klasteriranje u prostornoj domeni mogu se efikasno koristiti i metode veće računalne složenosti.

U poglavlju 5 izloženi su rezultati eksperimentalne evaluacije predložene metode segmentacije uz dva različita pristupa postprocesiranju u prostornoj domeni slike. Osnovni pristup za cilj ima eliminiranje segmenata manjih od predefiniranog kriterija. Ovaj postupak upravljan je parametrom ϑ koji određuje minimalnu veličinu segmenta. Drugi pristup temeljen je na efikasnoj metodi segmentacije slike particioniranjem grafa [12], prilagođene na način da se kao ulaz u algoritam segmentacije koristi inicijalna segmentacija dobivena filtriranjem u domeni boja. Ova metoda upravljana je dodatnim upravljačkim parametrom κ koji određuje skalu opservacije u prostornoj domeni. Važno je naglasiti da ovaj parametar ne određuje minimalnu veličinu komponente, koja je određena parametrom ϑ . Detalji metode efikasne segmentacije particioniranjem grafa dani su u dodatku B.

U oba slučaja, segmentacija slike predstavljena je u formi grafa G = (S, E) koji čine skup segmenata S i skup rubova $e^{(i)} \in E$ sa pripadajućim težinama $w^{(i)}$, pri

čemu je težina nenegativna mjera različitosti među segmentima koje rub povezuje. Skup S inicijalno čine segmenti dobiveni filtriranjem u domeni boja. Sortiranjem rubova grafa po rastućim težinama, za svaki segment sa brojem piksela manjim od ϑ upravo rub najmanje težine određuje najsličnijeg susjeda. Povezivanjem parova kod kojih je bar jedan od segmenata manji od ϑ može se dobiti konačna segmentacija kod koje svi segmenti zadovoljavaju kriterij veličine. Složenija obrada, temeljena na metodi efikasne segmentacije particioniranjem grafa, uključuje adaptivni kriterij odabira rubova analizom varijabilnosti unutar segmenta u odnosu na varijabilnost prema susjednim segmentima, pri čemu je postupak formiranja i sortiranja grafa zajednički za obje metode.

3.5 Analiza složenosti algoritma segmentacije

Opisana metoda segmentacije slike sastoji se od tri dijela: (1) filtriranje u domeni boja korištenjem adaptivnog histograma; (2) preslikavanje rezultata klasteriranja u domeni boja u prostornu domenu slike; (3) postprocesiranje u domeni slike. Za svaki od ova tri djela provest ćemo zasebnu analizu računalne složenosti.

1. Filtriranje u domeni boja

Konstrukcija histograma adaptivnom jezgrom odvija se u dvije faze. U prvom koraku određuje se inicijalna aproksimacija gustoće prebrojavanjem uzoraka, a složenost ovog postupka je O(2N), gdje je N broj ulaznih piksela slike. Fiksiranjem transformacije i granica domene boja, složenost postupka se smanjuje na O(N), uz povećanje memorijskih zahtjeva algoritma. Funkcija gustoće estimira se adaptivnom jezgrom. Složenost postupka određivanja konstante proporcionalnosti je O(M), gdje je M broj populiranih ćelija inicijalnog histograma, tj. ćelija koje sadrže bar jedan piksel ulazne slike. Složenost postupka estimacije gustoće adaptivnom jezgrom je O(cM), gdje je c konstanta koja ovisi o okolini u kojoj se računa doprinos svakog uzorka (piksela slike). Najgora varijanta složenosti javlja se za slučaj M = N, što bi značilo da svaki piksel ulazne slike zauzima zasebnu ćeliju histograma. U ovom slučaju, estimirana funkcija gustoće ne otkriva značajnije varijacije u strukturi podataka. Za otkrivanje značajnijeg informacijskog sadržaja, broj populiranih ćelija mora biti manji u odnosu na broj ulaznih podataka, a analizom estimirane gustoće moguće je otkrivanje trendova u podacima, te u realnom slučaju vrijedi $M \ll N$. Složenost postupka određivanja dominantnih boja i pridruživanja oznaka je

Složenost postupka određivanja dominantnih boja i pridruživanja oznaka je $O(2\delta M)$. Svakoj populiranoj ćeliji histograma pristupa se jednom za određivanje apsolutne razine šuma te ponovo u proceduri penjanja, a nepopulirane ćelije se preskaču. Korištenje jezgre za računanje doprinosa piksela slike funkciji gustoće može na granicama klastera rezultirati malim povećanjem broja ćelija histograma sa podrškom većom od nula u odnosu na broj populiranih ćelija. Koeficijent δ u analizu složenosti uključuje utjecaj jezgre na rubovima klastera u domeni boja, a ova vrijednost je u pravilu malo veća od jedan.

2. Preslikavanje u prostornu domenu slike

Za svaki piksel ulazne slike određuje se dominantna boja i oznaka pripadnosti temeljem histograma konstruiranog u prethodnom koraku. Složenost ovog postupka je O(N), tj. svakom pikselu slike pristupa se točno jednom.

3. Postprocesiranje

U ovom koraku moguće je primijeniti razne metode segmentiranja u prostornoj domeni, a složenost ovisi o odabranoj metodi. Analiza složenosti polazi od broja segmenata dobivenih filtriranjem u domeni boja, a koji je uvijek mnogo manji od broja piksela ulazne slike.

Ukupna složenost algoritma segmentacije približno je jednaka O(3N + (c+3)M), uvećano za složenost postupka dobivanja konačne segmentacije postprocesiranjem u prostornoj domeni. Kako je broj ulaznih podataka u postupak segmentiranja u prostornoj domeni relativno mali u odnosu na broj piksela slike, u ovoj fazi mogu se primijeniti i metode veće računalne složenosti uz zadržavanje efikasnosti obrade. Složenost algoritma dodatno se može smanjiti korištenjem fiksnih granica domene boja.

3.6 Upravljački parametri algoritma segmentacije

Adaptivna metoda segmentacije slike mrežom diskretnih elemenata ovisi o više parametara, koji uključuju: dimenzije ćelije histograma σ , fiksnu pojasnu propusnost $h_r^{(0)}$, faktor proporcionalnosti ρ , relativnu razinu šuma ε , te vrijednost ϑ koja definira minimalnu veličinu segmenta slike. Dodatni parametri ovise o primijenjenoj metodi postprocesiranja u prostornoj domeni. Širina ćelije histograma i pojasna propusnost u domeni boja međusobno su povezani te vrijedi $\sigma = h_r^{(0)}/\rho$. Dalje, primjenom Epanechnikove jezgre $K_E(x)$ (3.10) doprinos uzorka x_i iščezava za $|x - x_i| > h_r$, gdje je h_r varijabilna pojasna propusnost (3.23) čime je implicitno određena i $\sigma^{(i)}$ -okolina (3.35, 3.36) piksela x_i u kojoj se doprinos računa.

3.6.1 Faktor proporcionalnosti ρ

Odabir faktora proporcionalnosti ρ predstavlja kompromis između točnosti i efikasnosti. Veća vrijednost generira finiju granulaciju histograma za danu fiksnu pojasnu propusnost $h_r^{(0)}$, uz povećanje računalne složenosti postupka konstrukcije histograma. Na slikama 3.4, 3.5 i 3.6 prikazane su segmentacije ulazne slike dobivene za tri vrijednosti ovog parametra, uz fiksne vrijednosti ostalih upravljačkih parametara algoritma segmentacije.



Slika 3.4: Segmentacija slike za različite vrijednosti faktora proporcionalnosti ρ . Za $\rho = 9$ javlja se presegmentiranost, tj. rezultirajuća segmentacija sadrži veći broj detalja koji ne nose značajniji informacijski sadržaj.

Za ulaznu sliku (a) prikazanu na slici 3.4 rezultat prihvatljive kvalitete dobiva se već za $\rho = 1$ (b), a dodatni detalji otkrivaju se za $\rho = 3$ (c). Za vrijednost parametra $\rho = 9$ (d) vrijeme izvršavanja i memorijski zahtjevi algoritma značajno rastu, a rezultirajuća segmentacija subjektivno se može ocijeniti predetaljnom, tj. algoritam reagira na varijacije boje koje ne nose značajan informacijski sadržaj. Za sliku 3.5 algoritam ne može generirati dobru segmentaciju za $\rho = 1$, dok se za vrijednost parametra $\rho = 3$ i $\rho = 9$ dobiva sličan rezultat. Kod primjene na sliku 3.6, algoritam segmentacije daje prihvatljiv rezultat za sve tri vrijednosti parametra, sa više detalja za veće vrijednosti parametra.

U provedenim eksperimentima vrijednost ovog parametra fiksirana je na $\rho = 3$. Ova vrijednost parametra u pravilu daje segmentacije prihvatljive skale detalja, na kojima su izdvojena značajna područja slike. Za veće vrijednosti parametra ρ kvaliteta segmentacija se značajnije ne poboljšava, a povećanjem broja detalja malog informacijskog sadržaja može i opadati, uz smanjenje efikasnosti algoritma segmentacije.

3.6.2 Pojasna propusnost $h_r^{(0)}$

Pojasna propusnost osnovni je parametar svih metoda temeljenih na procjeni gustoće jezgrom. Za manje vrijednosti pojasne propusnosti, doprinos uzorka ima izražen lokalni karakter, a rezultirajuća funkcija gustoće otkriva više detalja u distribuciji podataka, dok je za veće vrijednosti ovog parametra rezultirajuća gustoća manje osjetljiva na lokalne varijacije podataka i otkriva detalje krupnije skale (slika 3.2). *AMBIS* metoda segmentacije slike pri procjeni gustoće koristi jezgru varijabilne pojasne propusnosti čime je povećana adaptivnost algoritma na ulazne podatke.

Na slikama 3.7, 3.8 i 3.9 prikazani su segmentacije ulaznih slika u ovisnosti o fiksnoj pojasnoj propusnosti $h_r^{(0)}$. Na slici 3.7 rezultat prihvatljive kvalitete dobiva se za sve tri vrijednosti parametra, pri čemu su za veće vrijednosti $h_r^{(0)}$ uočeni svi značajni elementi scene, uz smanjen broj detalja malog informacijskog sadržaja. Slični rezultati dobiveni su za segmentacije na slici 3.8. Za segmentacije na slici 3.9 kvaliteta opada za $h_r^{(0)} = 16$, za koju vrijednost parametra nisu uočeni bitni detalji na slici.

U eksperimentima opisanim u poglavlju 5 vrijednost ovog parametra birana je iz raspona $h_r^{(0)} \in [2, 16]$. Složenost i memorijski zahtjevi algoritma veći su za manje vrijednosti pojasne propusnosti.

3.6.3 Relativna razina šuma ε

Parametar ε definira relativnu razinu šuma, a koristi se u postupku određivanja značajnih žarišta funkcije gustoće i pripadajućih gravitirajućih područja. Prag šuma direktno utječe na prihvaćanje ili odbacivanje klastera domene boja kao relevantne informacijske strukture. Apsolutni prag šuma povezan je sa estimiranom funkcijom gustoće prema (3.37).

Na slikama 3.10, 3.11 i 3.12 prikazane su segmentacije dobivene algoritmom AM-BIS u ovisnosti o relativnom pragu šuma ε . Ni za jednu od tri ulazne slike ne postoji uočljiva razlika u dobivenim segmentacijama za različite vrijednosti parametra ε . Na slici 3.13 prikazan je broj značajnih žarišta domene boja (broj otkrivenih dominantnih boja na slici) sa podrškom većom od razine šuma $\xi = \varepsilon \Lambda$, gdje je Λ geometrijska sredina estimirane funkcije gustoće. Broj otkrivenih značajnih žarišta normaliziran je s obzirom na broj značajnih žarišta otkrivenih za $\varepsilon = 1$. Prikazana je srednja
vrijednost za sve slike Berkeley Segmentation Dataset [74] evaluacijske baze slika, opisane u poglavlju 4.3. Uočena osjetljivost algoritma segmentacije na parametar ε vrlo je mala. Pri $\varepsilon = 40$ broj značajnih žarišta je iznad 99% broja žarišta otkrivenih za $\varepsilon = 1$, za obje vrijednosti parametra $h_r^{(0)}$. Broj otkrivenih klastera nakratko se stabilizira u rasponu vrijednosti $\varepsilon \in [5, 15]$. U svim provedenim eksperimentima vrijednost ovog parametra fiksirana je na $\varepsilon = 9$.

3.6.4 Minimalna veličina segmenta ϑ

Algoritam segmentacije kao ulazni parametar prihvaća vrijednost ϑ koja definira minimalnu veličinu segmenta u konačnoj segmentaciji slike. Ukoliko je ova vrijednost zadana, u završnoj fazi obrade segmenti veličine manje od ϑ povezuju se sa najsličnijim susjedom, do zadovoljenja uvjeta $\forall s_i \in S : |s_i| \ge \vartheta$, gdje je $S = \{s_1, ..., s_K\}$ segmentacija slike u K segmenta.

Rezultirajuće segmentacije u ovisnosti o parametru ϑ , zadanom u obliku broja piksela slike, dana je slikama 3.14, 3.15 i 3.16. Može se uočiti stapanje manjih detalja sa susjednim većim segmentima za veće vrijednosti ovog parametra. Izbor parametra ϑ direktno određuje najmanju skalu detalja koji mogu biti izdvojeni u konačnoj segmentaciji, a ne utječe na način izvršavanja algoritma segmentacije. Vrijednost ovog parametra u provedenim eksperimentima fiksirana je na $\vartheta = 100$ piksela slike.

3.6.5 Dodatni upravljački parametri

Dodatni upravljački parametri algoritma segmentacije ovise o implementiranoj metodi procesiranja u prostornoj domeni, i nisu direktno povezani sa opisanom metodom. Primjenom metode efikasnog particioniranja grafa (EGB), uveden je dodatni parametar κ koji određuje skalu opservacije u prostornoj domeni. Način određivanja ove vrijednosti opisan je u dodatku B i izvornom radu [12].

Na slikama 3.17 i 3.17 prikazani su rezultati segmentiranja ulazne slike (a) uz dva različita pristupa procesiranju inicijalne segmentacije u prostornoj domeni slike. U prvom slučaju (b) primijenjen je jednostavan postupak povezivanja segmenata manjih od zadane veličine $\vartheta = 100$ piksela sa najsličnijim susjedom. U drugom slučaju (c), na inicijalnu segmentaciju primjenjena je metoda efikasne segmentacije grafa, uz parametar $\kappa = 400$, a konačan rezultat dobiven je stapanjem malih segmenata sa najsličnijim susjedom. Veća kvaliteta segmentacije dobivene uz *EGB* postprocesiranje uočljiva je na slici 3.17 na licu mlađeg djeteta, kod kojeg varijacije u boji i osvjetljenju rezultiraju presegmentiranošću osnovnom verzijom algoritma, dok je primjenom *EGB* metode ostvareno određeno poboljšanje. Na slici 3.18 nema

značajnije razlike u kvaliteti segmentacije dobivenih različitim tehnikama postprocesiranja, iako se segmentacije razlikuju u nekim detaljima.

Kvaliteta segmentacija dobivena AMBIS algoritmom uz postprocesiranje EGB metodom u ovisnosti o parametru κ prikazana je na slikama 3.19, 3.20 i 3.21. Može se uočiti da nema velike razlike za različite vrijednosti parametra, a u provedenim eksperimentima vrijednost ovog parametra birana je iz raspona $\kappa \in [100, 300]$.



(c) $\rho = 3$

(d) $\rho = 9$

Slika 3.5: Segmentacija slike za različite vrijednosti faktora proporcionalnosti $\rho.$ Za $\rho=1$ nisu otkrivene značajne cjeline na slici.



Slika 3.6: Segmentacija slike za različite vrijednosti faktora proporcionalnosti ρ . Za sve tri vrijednosti parametra dobivaju se segmentacije prihvatljive kvalitete. Za $\rho = 1$ algoritma ne uočava jasnu granicu kopna i neba u donjem desnom dijelu slike. Za $\rho = 9$ na nekim dijelovima slike može se uočiti izraženija presegmentiranost.



Slika 3.7: Segmentacija slike za različite vrijednosti fiksne pojasne propusnosti $h_r^{(0)}$. Za sve vrijednosti parametra rezultirajuće segmentacije su prihvatljive kvalitete.



Slika 3.8: Segmentacija slike za različite vrijednosti fiksne pojasne propusnosti $h_r^{(0)}$. Za sve vrijednosti parametra dobivaju se segmentacije prihvatljive kvalitete, uz izraženiju presegmentiranost za manje vrijednosti parametra.



Slika 3.9: Segmentacija slike za različite vrijednosti fiksne pojasne propusnosti $h_r^{(0)}$. Za $h_r^{(0)} = 16$ algoritam nije sposoban razlučiti granice broda, automobila i obale.



(c) $\varepsilon = 15$

Slika 3.10: Segmentacija slike za različite vrijednosti relativne razine šuma ε





(c) $\varepsilon = 15$

(d) $\varepsilon = 99$

Slika 3.11: Segmentacija slike za različite vrijednosti relativne razine šuma ε



(a) Ulazna slika

(b) $\varepsilon = 3$



Slika 3.12: Segmentacija slike za različite vrijednosti relativne razine šuma ε



Slika 3.13: Normalizirani broj značajnih žarišta u domeni boja u ovisnosti o relativnoj razini šuma ε . Broj značajnih žarišta normaliziran je s obzirom na broj značajnih žarišta za $\varepsilon = 1$. Prikazana je srednja vrijednost za sve slike u *Berkeley* Segmentation Dataset bazi slika opisanoj u poglavlju 4.3.



Slika 3.14: Segmentacija slike za različite vrijednosti minimalne veličine segmenta ϑ zadane u broju piksela



Slika 3.15: Segmentacija slike za različite vrijednosti minimalne veličine segmenta ϑ zadane u broju piksela



Slika 3.16: Segmentacija slike za različite vrijednosti minimalne veličine segmenta ϑ zadane u broju piksela



(a) Ulazna slika

(b) Segmentacija bezEGB postprocesiranja



(c) Segmentacija sa EGB postprocesiranjem

Slika 3.17: Segmentacija slike za dva načina postprocesiranja u prostornoj domeni: (b) postprocesiranje povezivanjem malih segmenata sa najsličnijim susjedom, (c) postprocesiranje efikasnom metodom segmentacije grafa. Razlika između segmentacija na slici (b) i (c) može se uočiti na licu mlađeg djeteta.



- (a) Ulazna slika
- (b) Segmentacija bezEGB postprocesiranja



(c) Segmentacija sa EGB postprocesiranjem

Slika 3.18: Segmentacija slike za dva načina postprocesiranja u prostornoj domeni: (b) postprocesiranje povezivanjem malih segmenata sa najsličnijim susjedom, (c) postprocesiranje efikasnom metodom segmentacije grafa. Iako se dobivene segmentacije u nekim detaljima razlikuju, nema značajnije razlike u kvaliteti.



Slika 3.19: Segmentacija slike uz postprocesiranje u prostornoj domeni metodom efikasne segmentacije grafa, za različite vrijednosti parametra κ



(c) $\kappa = 200$

(d) $\kappa = 400$

Slika 3.20: Segmentacija slike uz postprocesiranje u prostornoj domeni metodom efikasne segmentacije grafa, za različite vrijednosti parametr
a κ



Slika 3.21: Segmentacija slike uz postprocesiranje u prostornoj domeni metodom efikasne segmentacije grafa, za različite vrijednosti parametra κ

Poglavlje 4

Objektivna evaluacija metoda za segmentaciju slike

Razvoj algoritama za nenadgledanu segmentaciju slike došao je do točke u kojoj su ovi algoritmi sposobni ponuditi segmentacije koje se dobrim dijelom slažu sa ljudskom intuicijom. Efikasna implementacija razvijenih algoritama na modernom računalnom sklopovlju omogućava primjenu dobivenih rezultata kao korisne informacije u raznim složenim sustavima računalnog vida. Osnovni problem prilikom uključivanja algoritma za segmentaciju slike kao dio složenog sustava predstavlja objektivna procjena performansi algoritma, tj. kvalitete segmentacije koju je algoritam sposoban ponuditi. Kod brojnih autora prisutan je pristup kod kojeg je prezentirano više ulaznih testnih slika sa pripadajućim segmentacijama, a sama procjena kvalitete ponuđenih segmentacija prepuštena je intuiciji čitatelja. Nedostatak jasnih numeričkih rezultata za posljedicu ima nemogućnost direktne objektivne usporedbe različitih metoda segmentacije, što otežava implementaciju algoritma kao dijela složenog sustava. Pored ovog, nepostojanje jasne mjere kvalitete u velikoj mjeri otežava optimiranje parametara algoritma.

Usprkos naporima koji se ulažu u razvoj novih i poboljšanje postojećih metoda, tek u novije vrijeme napravljeni su značajniji koraci u smjeru uspostavljanja jasne metodologije za objektivnu kvantitativnu evaluaciju metoda za nenadgledanu segmentaciju slike. Dva osnovna problema koja je pri tom potrebno riješiti je stvaranje baze testnih slika te definiranje numeričke mjere kvalitete segmentacije koja omogućava direktnu usporedbu performansi različitih metoda.

Ostatak poglavlja organiziran je na slijedeći način: U poglavlju 4.1 dan je pregled postojećih mjera sličnosti različitih segmentacija nekog skupa podataka. U poglavlju 4.2 definiran je normalizirani probabilistički Rand indeks [72] i opisana su njegova svojstva. Baza slika koja će se u ovom radu koristiti kao testni skup podataka opisana je u poglavlju 4.3. O odnosu kvalitete dobivenih segmentacija i efikasnosti samog algoritma biti će riječi u poglavlju 4.4.

4.1 Mjere sličnosti

Kvantiziranje kvalitete segmentacije nekog skupa podataka na disjunktne podskupove složen je zadatak. Temeljni problem leži u činjenici da, osim za vrlo jednostavne ili umjetno generirane skupove, u pravilu ne postoji jedna apsolutno točna podjela. Sličan problem se javlja kada je potrebno utvrditi stupanj slaganja između rezultata dvije ili više različitih metoda klasteriranja. Segmentacija slike spada u skup slabo definiranih problema kod kojih ne postoji jedno *apsolutno istinito*¹ rješenje. Za točnu procjenu kvalitete neke segmentacije, ponuđeno rješenje potrebno je evaluirati temeljem skupa svih perceptualno logičnih segmentacija, od kojih je u najboljem slučaju samo mali dio dostupan. U realnom slučaju, dostupan je određen broj *istinitih* segmentacija koje su napravili ljudi, a sa kojima se segmentacija generirana algoritmom može usporediti.



Slika 4.1: Primjer segmentacija sa različitom skalom detalja: (a) ulazna slika, (b) i (c) dvije "istinite" segmentacije koje su napravili različiti ljudi

Razmotrimo slučaj kada je od više algoritama za segmentaciju slike potrebno odabrati jedan temeljem njihovih performansi na skupu slika. Algoritmi moraju biti objektivno ocijenjeni usporedbom segmentacija dobivenih svakim algoritmom sa manualno napravljenim *točnim* segmentacijama, od kojih je za svaku sliku dostupno nekoliko. Mjera kvalitete koja bi omogućila objektivnu usporedbu različitih algoritama mora zadovoljiti sljedeće zahtjeve [71]:

- Ne degenerativnost: Ne postoje degenerativni slučajevi kod kojih se za perceptualno nelogične segmentacije dobija visoka ocjena kvalitete.
- Bez pretpostavki o ulaznim podacima: Način ocjenjivanja ne sadrži implicitne pretpostavke o domeni i načinu generiranja podataka, kao što su broj ili približno jednake veličine segmenata na slici.

¹ground truth

- Adaptivnost na skalu segmentacije: Prirodne skupove u pravilu je moguće segmentirati u različitim skalama. Kod segmentacije slike, ovo se u prvom redu odnosi na razinu detalja koji se na slici izdvajaju kao zasebne cjeline. Razlika u uočavanju detalja kod segmentacije slike prisutna je i kod segmentacija koje su napravili ljudi (Slika 4.1), pa je i kod ocjenjivanja kvalitete računalno generiranih segmentacije potrebno uzeti u obzir mogućnost različitih skala detalja. Intuitivno, ovo zahtjeva mogućnost prilagodbe mjere kvalitete različitim skalama detalja u dijelovima slike kod kojih postoje razlike u skali i kod ručno generiranih segmentacija, te penaliziranje predetaljnog segmentiranja u onim dijelovima slike kod kojih su ručno generirane segmentacije konzistentne i bez detalja u finijoj skali.
- Usporedivi rezultati: Dobiveni rezultati moraju omogućiti jednostavnu usporedbu među različitim segmentacijama iste slike, kao i među segmentacijama različitih slika.

U postojećoj literaturi predloženo je nekoliko različitih pristupa za kvantitativnu evaluaciju kvalitete segmentacije. U sljedećim odjeljcima dan je pregled postojećih mjera kvalitete i njihov odnos prema navedenim zahtjevima.

4.1.1 Notacija

Neka je $X = \{x_1, x_2, ..., x_i, ..., x_N\}$ skup N ulaznih podataka (N piksela slike X). Segmentacija S je valjan skup oznaka pripadnosti koji svakom ulaznom podatku x_i pridružuje pripadajuću oznaku l_i . Oznake pripadnosti nazivamo i labele. Neka $S_1, S_2, ..., S_K$ označava skup K dostupnih skupova oznaka pripadnosti (K segmentacija). U svakom skupu oznaka pripadnosti S_k , labele mogu poprimiti jednu od L_k vrijednosti, gdje je L_k kardinalni broj skupa S_k . Indeks k u L_k naglašava moguće razlike u broju različitih oznaka pripadnosti u svakoj od segmentacija S_k .

Klasične mjere oblika $d(S_1, S_2)$ barataju sa slučajem K = 2 i daju usporedbu dvije segmentacije. U općem slučaju, za K > 2 tražimo mjeru $d(S_1, S_2, ..., S_K)$ koja kvantizira stupanj slaganja više segmentacija, tj. mjeri stupanj do kojeg dostupne segmentacije nisu u konfliktu. Ovako definiranu vrijednost nazivamo *mjera sličnosti* ili *mjera slaganja*. Predložene mjere možemo grubo podijeliti u nekoliko kategorija.

4.1.2 Mjere temeljene na sličnosti područja

Ova skupina mjera bazira se na računanju stupnja preklapanja klastera povezanog sa svakim ulaznim podatkom x_i u jednoj segmentaciji i njegove najbliže aproksimacije u nekoj drugoj segmentaciji [72]. Mjere temeljene na sličnosti područja u pravilu

nisu adaptivne s obzirom na rafiniranje skale opservacije, tj. penaliziraju razlike u skali uočenih detalja na segmentacijama koje se uspoređuju. S druge strane, brojna istraživanja potvrđuju da se razina detalja na kojoj ljudi opažaju sliku razlikuje od subjekta do subjekta. Neke od predloženih mjera razliku u skali detalja nadoknađuju dopuštanjem povećanja granularnosti segmentacije ravnomjerno na cijeloj slici. Greška lokalnog rafiniranja (*Local Refinement Error*) [74] definirana je sa (4.1):

$$E(S_1, S_2, x_i) = \frac{|R(S_1, x_i) \setminus R(S_2, x_i)|}{|R(S_1, x_i)|},$$
(4.1)

pri čemu je $R(S, x_i)$ skup piksela (segment slike) u S koji sadrži x_i , \ označava razliku te |X| kardinalni broj skupa X. Temeljem ove vrijednosti, autor definira grešku globalne konzistencije (Global Consistency Error) GCE i grešku lokalne konzistencije (Local Consistency Error) LCE:

$$GCE(S_1, S_2) = \frac{1}{N} \min\left\{\sum_i E(S_1, S_2, x_i), \sum_i E(S_2, S_1, x_i)\right\}$$
(4.2)

$$LCE(S_1, S_2) = \frac{1}{N} \sum_{i} \min \{ E(S_1, S_2, x_i), E(S_2, S_1, x_i) \}$$
(4.3)

Iz gornjih jednadžbi razvidno je da uvijek vrijedi $LCE(S_1, S_2) \leq GCE(S_1, S_2)$, tj. GCE je stroža mjera od LCE. Mjere kvalitete bazirane na različitosti područja imaju dva osnovna nedostatka:

- Degenerativnost: kao što je uočeno od strane samog autora [74, 75], postoje dvije trivijalne segmentacije za koje GCE i LCE uvijek daju grešku 0. Ovo su slučajevi kada je cijela slika jedan segment te kada svaki piksel slike predstavlja svoj segment. Kako ove mjere dopuštaju proizvoljno povećanje granularnosti segmentacije, korištenje procjene greške za usporedbu segmentacija limitirano je na slučajeve kada obje segmentacije imaju sličan kardinalni broj
- 2. Mjere bazirane na različitosti područja predložene u literaturi procjenjuju konzistentnost dvije različite segmentacije. Ova činjenica ograničava mogućnost evaluacije nekog algoritma na način da je za računalno generirane segmentacije moguća usporedba samo sa jednom ručno napravljenom segmentacijom koja u tom slučaju predstavlja apsolutnu istinu.

4.1.3 Mjere temeljene na preklapanju rubova

Nekoliko mjera predloženih u literaturi procjenjuju sličnost segmentacija preklapanjem rubova među područjima kod različitih segmentacija te proračunom nekog statističkog obilježja kvalitete preklapanja [75, 76]. Ove mjere u pravilu ne dopuštaju razlike u skali segmentacije pa je moguće da dvije segmentacije kod kojih je jedna savršena detaljnija segmentacija druge dobiju nisku ocjenu sličnosti. Dodatno, mjere bazirane na preklapanju rubova su osjetljive na relativno male perturbacije u položaju granice među područjima unutar segmentacije.

4.1.4 Statistički neparametarski testovi - Rand indeks

Ova skupina testova bazira se na statističkoj procjeni slaganja segmentacija. U statističkoj literaturi često je u upotrebi κ test [77] koji se koristi za evaluaciju klasifikacijskih algoritama, tj. segmentiranje prema predefiniranom modelu. Za procjenu stupnja slaganja dviju segmentacija sa potencijalno različitim kardinalnim brojem u literaturi je predložena mjera sličnosti [78] koja problem usporedbe segmentacija pretvara u problem proračuna međusobnih odnosa oznaka pripadnosti parova piksela.

Za dvije valjane segmentacije S i S' skupa N točaka $X = \{x_1, x_2, ..., x_N\}$, sa pripadajućim skupovima labela $\{l\}$ i $\{l'\}$, Rand indeks definiran je sa:

$$R(S,S') = \frac{1}{\binom{N}{2}} \sum_{\substack{i,j\\i < j}} \left[\mathbb{I}(l_i = l_j \wedge l'_i = l'_j) + \mathbb{I}(l_i \neq l_j \wedge l'_i \neq l'_j) \right]$$
(4.4)

gdje je I funkcija istinitosti, a vrijednost $\binom{N}{2}$ ukupan broj mogućih parova između N ulaznih podataka. Rand indeks računa udio ulaznih podataka koji u segmentacijama S i S' imaju isti međusobni odnos (podataka koji su u obje segmentacije u istoj kategoriji i podataka koji su u obje segmentacije klasificirani u različite kategorije. Važno je uočiti da ovako definirana mjera sličnosti ni na koji način ne ograničava broj jedinstvenih kategorija u S i S'.

4.2 Normalizirani probabilistički Rand indeks

Rand indeks definiranog jednadžbom (4.4) direktno je primjenjiv za slučaj K = 2, tj. za procjenu sličnosti dvije segmentacije nekog skupa podataka. Za primjenu na opći slučaj K > 2 ovu mjeru je potrebno proširiti na način koji omogućava procjenu slaganja više dostupnih segmentacija.

4.2.1 Probabilistički Rand Indeks

Pretpostavimo da postoji skup $\{S_1, S_2, ..., S_K\}$ manualno napravljenih *istinitih* segmentacija koje odgovaraju skupu ulaznih podataka $X = \{x_1, x_2, ..., x_N\}$ i segmentacija S^{test} koju je potrebno usporediti sa skupom *istinitih* segmentacija $\{S_k\}$. Labele pripadnosti $l_i^{S_{test}}$ točaka x_i u segmentaciji S^{test} poprimaju jednu od diskretnih L_{test} vrijednosti. Temeljem skupa *istinitih* segmentacija može se izračunati empirijsku vjerojatnost [71] međusobnog odnosa para ulaznih točaka x_i i x_j :

$$\hat{p}(l_i = l_j) = \frac{1}{K} \sum_{k=1}^{K} \mathbb{I}\left(l_i^{(k)} = l_j^{(k)}\right)$$
(4.5)

$$\hat{p}(l_i \neq l_j) = \frac{1}{K} \sum_{k=1}^{K} \mathbb{I}\left(l_i^{(k)} \neq l_j^{(k)}\right)$$

$$= 1 - \hat{p}(l_i = l_j)$$
(4.6)

Korištenjem vrijednosti dobivenih prema (4.5,4.6) možemo definirati Probabilistički Rand indeks [71, 72] kao mjeru slaganje segmentacije koju evaluiramo sa dostupnim *istinitim* segmentacijama:

$$PR(S_{test}, \{S_1, ..., S_K\}) = \frac{1}{\binom{N}{2}} \sum_{\substack{i,j \\ i < j}} \left[\mathbb{I} \left(l_i^{S_{test}} = l_j^{S_{test}} \right) \hat{p} \left(l_i = l_j \right) + \mathbb{I} \left(l_i^{S_{test}} \neq l_j^{S_{test}} \right) \hat{p} \left(l_i \neq l_j \right) \right]$$
(4.7)

Uvedimo oznake

$$p_{ij} = \hat{p}(l_i = l_j) \tag{4.8}$$

$$c_{ij} = \mathbb{I}\left(l_i^{S_{test}} = l_j^{S_{test}}\right) \tag{4.9}$$

gdje c_{ij} označava događaj kada par ulaznih podataka x_i, x_j imaju istu oznaku pripadnosti (labelu) u S^{test} , jednadžbu (4.7) možemo pisati kao

$$PR(S_{test}, \{S_1, ..., S_K\}) = \frac{1}{\binom{N}{2}} \sum_{\substack{i,j \\ i < j}} [c_{ij}p_{ij} + (1 - c_{ij})(1 - p_{ij})]$$
(4.10)

Kako varijabla c_{ij} uzima diskretne vrijednosti iz skupa $c_{ij} \in \{0, 1\}$, jednadžbu (4.10) možemo zapisati kao

$$PR(S_{test}, \{S_1, ..., S_K\}) = \frac{1}{\binom{N}{2}} \sum_{\substack{i,j \\ i < j}} \left[p_{ij}^{c_i j} (1 - p_{ij})^{(1 - c_{ij})} \right]$$
(4.11)

PR indeks može primiti vrijednost u rasponu [0, 1], pri čemu se slučajevi PR = 0ili PR = 1 mogu dogoditi u sljedećim situacijama: PR = 0 - segmentacije S_{test} i $\{S_1, S_2, ..., S_K\}$ nemaju nikakvih sličnosti (npr. *S* svrstava sve ulazne podatke u jedan klaster, dok se sve segmentacije $\{S_k\}$ sastoje od klastera kod kojih svaki sadrži samo jedan ulazni podatak, ili obratno); PR = 1 - sve segmentacije iz skupa $\{S_1, S_2, ..., S_K, S_{test}\}$ su identične. U realnom slučaju, ukoliko *istinite* segmentacije $\{S_1, S_2, ..., S_K\}$ nisu identične, *PR* indeks ne može nikada imati vrijednost 1. Ilustrirajmo ovo sljedećim primjerom.



Slika 4.2: Dvije *istinite* segmentacije hipotetske slike

Zamislimo sliku X veličine N piksela i dvije njezine segmentacije prikazane na slici 4.2. Segmentacija S_1 sve piksele slike klasificira kao jedan segment, segmentacija S_2 dijeli sliku vertikalno na dva djela. Ukoliko prema jednadžbi (4.5) za proračun empirijske vjerojatnosti odnosa para točaka koristimo segmentacije $\{S_1, S_2\}$, dobiva se sljedeća distribucija vjerojatnosti:

$$\hat{p}(l_i = l_j) = \begin{cases} 1 & \text{za} \quad (x_i, x_j) \in R1 \lor (x_i, x_j) \in R2\\ 0.5 & \text{za} \quad (x_i \in R1 \land x_j \in R2)\\ 0.5 & \text{za} \quad (x_i \in R2 \land x_j \in R1) \end{cases}$$
(4.12)

Izračunate vrijednosti opisuju situaciju u kojoj je čovjeku perceptualno jednako vjerojatno da je cijela slika jedna cjelina, kao i da je sastavljena od dva vertikalno razdvojena segmenta. Neslaganje *istinitih* segmentacija postavlja gornju granicu na vrijednost PR indeksa za bilo koju testnu segmentaciju S te se iz (4.12) lako da izračunati da vrijedi

$$\lim_{N \to \infty} PR_{max}(S, \{S_1, S_2\}) = \frac{3}{4}$$
(4.13)

Ova vrijednost PR indeksa dobiva se ukoliko je testna segmentacija ekvivalentna segmentaciji S_1 ili S_2 , dok za bilo koju drugu moguću segmentaciju S vrijedi

$$PR(S, \{S_1, S_2\}) < \frac{3}{4} \tag{4.14}$$

Bitno svojstvo PR indeksa je tolerantnost prema povećanju skale detalja, sve dok je ponuđeno rješenje konzistentno sa nekom od *istinitih* segmentacija na kojima se temelji evaluacija. Na slici 4.3 je dan primjer ulazne slike i dvije *istinite* segmentacije,



Slika 4.3: Tolerantnost PR indeksa prema rafiniranju skale detalja. Redom su prikazane: (a) ulazna slika; dvije *istinite (ground truth)* segmentacije (b) i (c); segmentacije (d), (e) i (f) za koje se računaPR indeks temeljem dostupnih *istinitih* segmentacija. Sve podjele na testnim segmentacijama (d) i (f) prisutne su i na *istinitim* segmentacijama. Segmentacija (e) dijeli sliku vertikalno po sredini, na način koji nije prisutan u *istinitim* segmentacijama.

od kojih je prva (slika 4.3(b)) temeljena na teksturi, dok je druga (slika 4.3(c)) temeljena na boji ulazne slike. Empirijska vjerojatnost p_{ij} međusobnog odnosa para ulaznih točaka x_i, x_j definirana sa (4.8) izračunata iz *istinitih* segmentacija S_1, S_2 dana je u tablici 4.1.

Temeljem izračunatih empirijskih vjerojatnosti, može se odrediti gornja granica na vrijednost PR indeksa za dostupne *istinite* segmentacije, na način da se za svaki par piksela ulazne slike odabere najpovoljniji odnos, tj. pripadnost istom ili različitim segmentima koja maksimizira PR indeks. Prema tablici 4.1, maksimalna vrijednost PR indeksa dobiva se ukoliko se svim pikselima čiji odnos zadovoljava prvu skupinu uvjeta pridruži ista labela, svim pikselima čiji odnos zadovoljava treću skupinu uvjeta pridruži različita labela, dok je za piksele druge skupine jednaka vjerojatnost da pripadaju istom ili različitim segmentima. Prema jednadžbi (4.8)

odnos točaka	broj parova
$ \begin{array}{c} (x_1, x_2) \in R_1 \\ (x_1, x_2) \in R_2 \\ (x_1, x_2) \in R_3 \\ (x_1, x_2) \in R_4 \end{array} \right\} \begin{array}{c} p_{ij} = 1 \\ 1 - p_{ij} = 0 \end{array} $	$4 \cdot \binom{N/4}{2}$
$ \begin{pmatrix} x_1 \in R_1 \land x_2 \in R_2) \lor (x_1 \in R_2 \land x_2 \in R_1) \\ (x_1 \in R_2 \land x_2 \in R_3) \lor (x_1 \in R_3 \land x_2 \in R_2) \\ (x_1 \in R_3 \land x_2 \in R_4) \lor (x_1 \in R_4 \land x_2 \in R_3) \\ (x_1 \in R_4 \land x_2 \in R_1) \lor (x_1 \in R_1 \land x_2 \in R_4) \end{pmatrix} p_{ij} = 0.5 $	$4 \cdot \left(\frac{N}{4}\right)^2$
$ \begin{array}{c} (x_1 \in R_1 \land x_2 \in R_3) \lor (x_1 \in R_3 \land x_2 \in R_1) \\ (x_1 \in R_2 \land x_2 \in R_4) \lor (x_1 \in R_4 \land x_2 \in R_2) \end{array} \right\} \begin{array}{c} p_{ij} = 0 \\ 1 - p_{ij} = 1 \end{array} $	$2 \cdot \left(\frac{N}{4}\right)^2$

Tablica 4.1: Empirijske vjerojatnosti temeljene dostupnim na *istinitim* segmentacijama za sliku 4.3(a)

računa se maksimalni PR indeks:

$$PR_{max}(S, \{S_1, S_2\}) = \frac{1}{\binom{N}{2}} \left[4\binom{N/4}{2} \times 1 + 4\left(\frac{N}{4}\right)^2 \times 0.5 + 2\left(\frac{N}{4}\right)^2 \times 1 \right]$$
$$= \frac{2}{N(N-1)} \cdot \frac{3N^2 - 4N}{8} = \frac{3N - 4}{4N - 4}, \tag{4.15}$$

te vrijedi

$$\lim_{N \to \infty} PR_{max}(S, \{S_1, S_2\}) = \frac{3}{4}$$
(4.16)

Maksimalna vrijednost PR indeksa dobija se za obje *istinite* segmentacije.

Temeljem dostupnih *istinitih* segmentacija mogu se na sličan način izračunati vrijednosti PR indeksa za testne segmentacije $S_{test1}, S_{test2}, S_{test3}$:

$$\lim_{N \to \infty} PR(S_{test1}, \{S_1, S_2\}) = \frac{3}{4}$$
(4.17)

$$\lim_{N \to \infty} PR(S_{test2}, \{S_1, S_2\}) = \frac{11}{16}$$
(4.18)

$$\lim_{N \to \infty} PR(S_{test3}, \{S_1, S_2\}) = \frac{3}{4}$$
(4.19)

Iako su segmentacije S_{test1} i S_{test3} detaljnije nego bilo koja od *istinitih* segmentacija, neslaganje postoji samo u dijelovima na kojima se ni *istinite* segmentacije ne slažu. Podjele koje su prisutne na ovim segmentacijama postoje barem na jednoj od *istinitih* segmentacija, a obje segmentacije ocijenjene su maksimalnom mogućom vrijednošću PR indeksa. Segmentacija S_{test2} sadrži podjelu u području u kojem se

istinite segmentacije slažu te je ocijenjena je nešto nižim PR indeksom.

4.2.2 Normalizacija

Probabilistički Rand indeks ispunjava većinu postavljenih zahtjeva za objektivnu mjeru sličnosti. Degenerativni slučajevi koji se ne slažu ni sa jednom od dostupnih *istinitih segmentacija* penaliziraju se niskom vrijednošću PR indeksa. Dalje, ne postoje nikakva ograničenja na broj ili veličinu segmenata, niti bilo kakve druge pretpostavke o načinu generiranja podataka. Mjera je adaptivna na skalu segmentacije, ali samo u onim dijelovima u kojima se ni ručno generirane segmentacije ne slažu, tj. sve dok je ponuđeno rješenje konzistentno sa barem jednom od dostupnih *istinitih* segmentacija. Izračunata vrijednost PR indeksa omogućava direktnu usporedbu među različitim segmentacijama iste slike, čime je djelomično ispunjen i četvrti navedeni zahtjev.

Kvaliteta neke mjere usko je povezana sa intuitivnom vrijednošću informacije koju opisana mjera pruža, pri čemu informacijski sadržaj direktno ovisi o poznavanju očekivane vrijednosti mjere. Iako je raspon vrijednosti koje probabilistički Rand indeks može primiti poznat ($PR \in [0, 1]$), izračunata vrijednost indeksa ne daje jasnu informaciju o kvaliteti dobivenog rezultata. Ilustrirajmo ovo primjerom na slici 4.3 na način da se kao *istinite* segmentacije koriste segmentacije S_1 (slika 4.3(b)), S_2 (slika 4.3(c)) i S_{test1} (slika 4.3(d)). Maksimalna vrijednost PR indeksa kojom neka segmentacija može biti ocijenjena temeljem skupa *istinitih* segmentacija $\{S_1, S_2, S_{test1}\}$ raste i vrijedi

$$\lim_{N \to \infty} PR_{max}(S, \{S_1, S_2, S_{test1}\}) = \frac{5}{6}$$
(4.20)

U ovom slučaju, jednaka vrijednost PR indeksa za neku evaluiranu segmentaciju znači 10% nižu kvalitetu u odnosu na istu vrijednost PR indeksa dobivenu evaluacijom temeljenom na skupu *istinitih* segmentacija $\{S_1, S_2\}$.

Maksimalna vrijednost PR indeksa ovisi o stupnju slaganja *istinitih* segmentacija, tj. o složenosti ulazne slike. Visok stupanj slaganja segmentacija koje naprave ljudi može se dobiti za jednostavne ulazne slike, dok za složenije slike, razlike među *istinitim* segmentacijama mogu biti značajne, najčešće kao posljedica razlike u skali opservacije (primjer na slici 4.1). Bez poznavanja očekivane vrijednosti mjere, PRindeks ne nosi informaciju temeljem koje bi se mogla usporediti kvaliteta segmentacija različitih slika. Intuitivnog informacijski sadržaj neke mjere može se povećati normalizacijom u odnosu na očekivanu vrijednost:

$$Normalizirana mjera = \frac{Mjera - O\check{c}ekivana vrijednost}{Maksimalna vrijednost - O\check{c}ekivana vrijednost}$$
(4.21)

Očekivana vrijednost normalizirane mjere je nula (za Mjera = Očekivana vrijednost), maksimalna vrijednost normalizirane mjere je 1, a raspon mogućih vrijednosti se širi na negativne vrijednosti za Mjera < Očekivana vrijednost, čime se efektivno povećava osjetljivost mjere.

Za proračun normalizirane vrijednost indeksa i primjenu na problem segmentacije slike, potrebno je odrediti očekivanu vrijednost PR indeksa:

$$\mathbb{E}\left[PR(S, \{S_1, ..., S_K\})\right] = \frac{1}{\binom{N}{2}} \sum_{\substack{i,j \\ i < j}} \left\{ \mathbb{E}\left[\mathbb{I}\left(l_i^S = l_j^S\right)\right] p_{ij} + \mathbb{E}\left[\mathbb{I}\left(l_i^S \neq l_j^S\right)\right] (1 - p_{ij})\right\} = \frac{1}{\binom{N}{2}} \sum_{\substack{i,j \\ i < j}} \left[p'_{ij}p_{ij} \left(1 - p'_{ij}\right)(1 - p_{ij})\right]$$

pri čemu je osnovni problem proračun očekivane vrijednosti

$$p'_{ij} = \mathbb{E}\left[\mathbb{I}\left(l_i^S = l_j^S\right)\right] \tag{4.23}$$

Očekivane vrijednost p'_{ij} može se dobiti iz kolekcije slučajnih, ali realističnih slika, sa pripadajućim skupom *istinitih* segmentacija, kojih je za svaku sliku u kolekciji dostupno nekoliko. Neka je Φ broj slika u kolekciji te K_{ϕ} broj *istinitih* segmentacija za sliku ϕ . Tada očekivanu vrijednost p'_{ij} možemo prema [72] definirati kao

$$p'_{ij} = \frac{1}{\Phi} \sum_{\phi=1}^{\Phi} \frac{1}{K_{\phi}} \sum_{k=1}^{K_{\phi}} \mathbb{I}\left(l_{i}^{S_{k}^{\phi}} = l_{j}^{S_{k}^{\phi}}\right)$$
(4.24)

Uvrštavanjem jednadžbe (4.24) u (4.22) može se dobiti formula za proračun očekivane vrijednost $\mathbb{E}\left[PR(S, \{S_1, ..., S_K\})\right]$ za promatranu sliku sa pripadajućim skupom K istinitih segmentacija $\{S_1, ..., S_K\}$:

$$\mathbb{E}\left[PR(S, \{S_1, ..., S_K\})\right] = \frac{1}{\Phi} \sum_{\phi=1}^{\Phi} \frac{1}{K_{\phi}} \sum_{k=1}^{K_{\phi}} \left\{ \frac{1}{\binom{N}{2}} \sum_{\substack{i,j \ i < j}} \left[\mathbb{I}(l_i^{S_k^{\phi}} = l_j^{S_k^{\phi}}) \frac{1}{K} \sum_{z=1}^K \mathbb{I}(l_i^{S_z^{\phi}} = l_j^{S_z^{\phi}}) + \mathbb{I}(l_i^{S_k^{\phi}} \neq l_j^{S_k^{\phi}}) \frac{1}{K} \sum_{z=1}^K \mathbb{I}(l_i^{S_z^{\phi}} \neq l_j^{S_z^{\phi}}) \right] \right\}$$
(4.25)

Vrijednost definirana jednadžbom (4.25) implicira da je očekivana vrijednost *Rand* indeksa ponderirana suma $PR(S_k^{\phi}, \{S_1, ..., S_K\})$:

$$\mathbb{E}\left[PR(S, \{S_1, ..., S_K\})\right] = \frac{1}{\Phi} \sum_{\phi=1}^{\Phi} \frac{1}{K_{\phi}} \sum_{k=1}^{K_{\phi}} PR\left(S_k^{\phi}, \{S_1, ..., S_K\}\right)$$
(4.26)

Kako su vrijednosti p'_{ij} i p_{ij} dobivene iz empirijskih podataka, broj i veličina segmentiranih regija na slikama ne moraju biti konstantni, a kvaliteta dviju segmentacija iste slike sa različitim brojem segmenta može biti direktno uspoređena. Dalje, kako je vrijednost p'_{ij} dobivena korištenjem svih *istinitih* segmentacija, a ne samo segmentacija za promatranu sliku, moguće je usporediti kvalitetu segmentacija za različite slike s obzirom na pripadajuće *istinite* segmentacije. Normalizirani probabilistički Rand indeks [72] računamo kao:

$$NPR\left(S, \{S_1, ..., S_K\}\right) = \frac{PR\left(S, \{S_1, ..., S_K\}\right) - \mathbb{E}\left[PR(S, \{S_1, ..., S_K\})\right]}{1 - \mathbb{E}\left[PR(S, \{S_1, ..., S_K\})\right]} \quad (4.27)$$

Normalizirani probabilistički Rand indeks nije temeljen na implicitnim pretpostavkama o strukturi ulaznih podataka (broju, obliku ili veličini segmenata slike) i daje objektivnu mjeru kvalitete različitih segmentacija iste slike, sa različitim brojem segmenata. Normalizacijom u odnosu na očekivanu vrijednost PR indeksa za slučajne, ali realistične segmentacije, ova veličina može se uzeti kao apsolutna mjera kvalitete, a ne samo kao relativan odnos kvalitete segmentacija koje se uspoređuju [73], te se može zaključiti da svaka segmentacija ocijenjena vrijednošću NPR indeksa većom od nula nosi koristan informacijski sadržaj. Dalje, normalizacijski korak omogućava objektivnu i jasnu usporedbu kvalitete segmentacija različitih slika, generiranih različitim algoritmima temeljem različitih značajki vizualne informacije.

4.3 Berkeley Segmentation Dataset

Definiranjem jasne kvantitativne mjere kvalitete zadovoljen je jedan od dva preduvjeta za evaluaciju algoritama segmentacije. Drugi nužan preduvjet za provedbu opsežnijeg istraživanja i objektivne komparacije različitih metoda je postojanje skupa ulaznih podataka, tj. dovoljno velike baze slika različitih motiva koje na ni jedan način ne favoriziraju određeni algoritam, kao i pripadnog skupa segmentacija koje su izradili ljudi i koje se kod evaluacije mogu smatrati *istinitim* ili *točnim* segmentacijama.

Način na koji čovjek segmentira sliku u perceptualno logične cjeline bazira se na brojnim parametrima niske razine, kao što su varijacije u boji i svjetlini, tekstura, rubovi, postojanje simetrije i slično. Pored ovog, u procesu segmentacije čovjek se koristi informacijama više razine i iskustvom, kao na primjer uočavanju poznatih objekata na slici. Algoritmi za računalnu segmentaciju u pravilu izdvajaju jednu ili nekoliko osobina niske razine, temeljem kojih ulaznu sliku dijele na segmente unutar kojih su oscilacije promatranih osobina manje u odnosu na razlike u vrijednostima prema ostalim dijelovima slike, pri čemu različiti algoritmi koriste različiti skup osobina niske razine. Problem procjene kvalitete segmentacija dobivenih računalnim algoritmom može se svesti na procjenu konzistentnosti dobivenih segmentacija sa ljudskim poimanjem logične podjele ulazne slike na cjeline. Ovaj postupak često je ograničen na relativno mali broj ulaznih slika na kojima je perceptualno logična podjela na područja u najvećem dijelu posljedica osobina na kojima je baziran algoritam. Pored ovog, kao temeljna istina (Ground Truth - GT), tj. točna segmentacija sa kojom se računalno dobivene segmentacije uspoređuju često se koristi samo jedna ručno napravljena segmentacija. Neka od u literaturi predloženih rješenja uključuju subjektivnu kvantitativnu ocjenu kvalitete dobivenih rezultata [79] na predefiniranom setu slika temeljnu na prepoznatljivosti segmentiranih rubova objekata na slici. Osnovni argument kojim autori obrazlažu ovaj pristup je nepostojanje jedne apsolutno točne segmentacije sa kojim bi dobiveno rješenje bilo moguće usporediti.

U eksperimentima provedenim u ovom radu korištena je Berkeley Segmentation Dataset (BSD) baza slika [74] razvijena na Berkeley University of California, Computer Vision Group. Ova baza sastavljena je od 300 fotografija kompleksnih prirodnih scena različitih motiva, pri čemu je za svaku sliku dostupno nekoliko istinitih, ručno napravljenih segmentacija. Subjekti koji su učestvovali u procesu kreiranja baze segmentacija upućeni su da svaku sliku podjele na segmente, pri čemu svaki od segmenata predstavlja konceptualno logičnu cjelinu. Subjekti nisu ni na koji način instruirani o načinu segmentiranja. Da bi se povećala objektivnost pri izradi baze, razvijena je Java aplikacija koja je operaterima olakšavala postupak generiranja segmentacije, uz istovremeno osiguravanje sljedećih uvjeta: (a) ni jedan subjekt nije vidio istu sliku dva puta; (b) ne postoje dvije slike koje su segmentirane od potpuno iste skupine subjekata.

Sam zadatak izrade segmentacija definiran je na slijedeći način:

"Podijelite svaku sliku na dijelove, pri čemu svaki dio predstavlja zasebnu stvar na slici. Važno je da svi dijelovi imaju približno jednaku važnost. Broj djelova slike ovisi o vama. Okvirni broj između 2 i 20 djelova trebao bi biti prihvatljiv izbor za svaku sliku.²

Ovako definiran zadatak osigurava nepristranost subjekata pri izradi segmentacija. Dobivene segmentacije razlikuju se u skali detalja koje razni subjekti percipiraju kao važne cjeline na slici. Isto tako, ni na koji način se ne određuje izbor osobina koje određuju perceptualno logične cjeline.

Na slici 4.4 dan je primjer fotografije iz *BSD* baze sa četiri različite segmentacije koje su napravili ljudi. Na slici (a) prikazana je ulazna slika. Na slici (b) prikazana je

²Prijevod s engleskog: "Divide each image into pieces, where each piece represents a distinguished thing in the image. It is important that all of the pieces have approximately equal importance. The number of things in each image is up to you. Something between 2 and 20 should be reasonable for any of our images."



Slika 4.4: Ulazna slika i pripadajuće *istinite* segmentacije koje su napravili ljudi (Berkeley Segmentation Dataset)

segmentacija napravljena pod velikim utjecajem informacija više razine (sve jedrilice na slici segmentirane su kao cjeline, usprkos velikim razlikama između npr. jedara i trupa broda). Segmentacija na slici (c) slična je prvoj segmentaciji, uz precizniju skalu detalja (svako jedro je zaseban segment). Na posljednje dvije segmentacije javljaju se dodatni detalji. Iz slike (e) razvidno je da se subjekt prilikom izrade segmentacije vodio vizualnim informacijama niže razine, tj. varijacijama u boji, bez korištenja iskustva i prepoznavanja objekata na slici.

Iz primjera na slici 4.4 jasna je razlika u pristupu i skupu informacija koje različiti ljudi koriste prilikom podjele slike u perceptualno logične cjeline. Za računalni algoritam koji se kod segmentiranje oslanja na podskup značajki niže razine koje čine manji dio ukupne vizualne informacije nije realno očekivati da kvalitetom rezultata dostigne razinu ručno izrađenih segmentacija. Međutim, ovako definiran skup testnih podataka omogućava direktnu usporedbu kvalitete rezultata dobivenih različitim algoritmima, bez obzira koriste li pri tom isti skup značajki ili potpuno različite informacije, kao i usporedbu sa segmentacijama koje su napravili ljudi.

4.4 Točnost i efikasnost

Pored kvalitete dobivenih segmentacija, osnovni parametar koji određuje mogućnost primjene nekog algoritma u realnim sustavima računalnog vida predstavlja efikasnost obrade ulaznih podataka. Ovo se u prvom redu odnosi na sustave koji rade u stvarnom vremenu, a kod kojih odnos točnosti i efikasnosti mora biti takav da algoritam segmentacije daje rezultate prihvatljive kvalitete u što kraćem vremenu. Teoretska procjena računalne složenosti algoritma dobiva se analizom postupka segmentacije, a poželjna osobina svake metode je složenost linearna broju piksela slike.

Odnos točnosti i efikasnosti evaluiranih algoritama ispitati će se eksperimentalno, usporedbom vremena obrade ulaznih slika. Za relevantne rezultate eksperimentalne analize efikasnosti, nužno je osigurati jednake uvjete za svaki od testiranih algoritama, što uključuje:

1. Kvalitetnu implementaciju algoritma računalnim programom

Svi testirani algoritmi implementirani su od strane samih autora, čime je eliminirana moguća subjektivnost u pristupu implementaciji. Sve implementacije prevedene su u izvršni kod istim programskim prevodiocem sa uključenom jednakom razinom optimizacije izvršnog koda. Dodatno, osigurana je identična implementacija koraka zajedničkih svim testiranim algoritmima (učitavanje i snimanje slika, konverzije prostora boja).

2. Jednake uvjete izvršavanja

Svi eksperimenti izvršeni su na identičnom računalnom sklopovlju, pri čemu je u najvećoj mogućoj mjeri osigurano da za vrijeme provođenja eksperimenata testna računala ne izvršavaju druge zadaće.

Svi eksperimenti opisani u ovom radu provedeni su na unificiranim resursima računalnog klastera na Fakultetu elektrotehnike, strojarstva i brodogradnje, koji je dio EGEE (Enabling Grids for E-sciencE)³ grid infrastrukture. Klaster je izgrađen korištenjem 64 bitnih SUN Fire X4100 servera, a organiziran je na slijedeći način:

• Pristupna točka⁴

SUN Fire X4100, $1 \times$ AMD Opteron CPU 2Ghz, 1GB RAM

³http://www.eu-egee.org ⁴front end

- Jedinica za pohranu⁵ SUN Fire X4100, 1× AMD Opteron CPU 2Ghz, 1GB RAM
- Produkcijski čvorovi (6 čvorova) SUN Fire X4100, 2× Dual Core AMD Opteron CPU 2Ghz, 4GB RAM

Sustav za upravljanje poslovima⁶ osigurava da se prilikom pokretanja svakog zadatka alocira točno jedna procesorska jezgra, čime je omogućeno istovremeno izvršavanje 24 nezavisna procesa na produkcijskim čvorovima klastera.

Sa ciljem utvrđivanja svih osobina algoritma segmentacije značajnih za implementaciju u stvarnom sustavu računalnog vida, eksperimentalno će se ispitati efikasnosti izvršavanja svake od promatranih metoda u ovisnosti o dimenzijama slike i upravljačkim parametrima algoritma.

⁵storage unit

⁶job management system

Poglavlje 5 Komparativna evaluacija

U ovom poglavlju prezentirani su rezultati eksperimentalne analize kvalitete i efikasnosti predložene metode adaptivne segmentacije slike mrežom diskretnih elemenata, opisane u poglavlju 3. Dobiveni rezultati podijeljeni su u dvije skupine, s obzirom na način postprocesiranja u prostornoj domeni slike. U prvom slučaju, primijenjen je jednostavan postupak povezivanja malih segmenata do zadovoljenja uvjeta minimalne veličine segmenta. Drugi pristup uključuje postprocesiranje inicijalne segmentacije dobivene filtriranjem u domeni boja tehnikom efikasne segmentacije grafa [12]. Kvaliteta dobivenih segmentacija evaluirana je korištenjem Berkeley Segmentation Dataset baze slike [74]. Ova javno dostupna baza, opisana u poglavlju 4.3 sadrži 300 slika sa pet do sedam ručno napravljenih istinitih (Ground Truth) segmentacija, za svaku od slika u bazi. Mjera kvalitete segmentacija generiranih računalnim algoritmom je normalizirani probabilistički Rand indeks (NPR) [72], opisan u poglavlju 4.2. Eksperimenti su podijeljeni u dva dijela. Prva skupina eksperimenata provedena je sa ciljem procjene kvalitete računalno generiranih segmentacija te osjetljivosti kvalitete dobivenih rezultata s obzirom na upravljačke parametre algoritma i na različite slike. U drugoj skupini eksperimenata analizirana je efikasnost algoritma segmentacije u ovisnosti o upravljačkim parametrima algoritma i dimenzijama ulaznih slika.

Kvaliteta i efikasnost predložene metode adaptivne segmentacije slike mrežom diskretnih elemenata evaluirana je u usporedbi sa dvije postojeće metode segmentacije slike. Metoda srednjeg pomaka (Mean Shift - MS) [15, 16], opisana u dodatku A, temelji se na analizi prostora značajki¹ i procjeni funkcije gustoće vjerojatnosti u združenoj prostornoj domeni i domeni boja [2, 3, 4]. Za razliku od predložene metode segmentacije slike diskretizacijom prostora, algoritam srednjeg pomaka lokalne maksimume estimirane funkcije gustoće i pripadajuća gravitirajuća područja pronalazi analitički, određivanjem gradijenta estimirane gustoće. Ova metoda široko je prihvaćena i implementirana u brojnim sustavima računalnog vida. Druga korištena metoda je tehnika efikasne segmentacije slike temeljena na grafu (Efficient Graph-Based Image Segmentation - EGB) [12]. Ova metoda, opisana u dodatku B, točke

 $^{^1}feature\ space\ analysis$

prostorne domene slike organizira u formu grafa sa težinama rubova koje odgovaraju udaljenostima točaka u domeni boja, a konačni rezultat se dobiva primjenom adaptivnog kriterija postojanja granice među komponentama segmentacije. Metoda srednjeg pomaka i metoda efikasne segmentacije temeljena na grafu predstavnici su različitih pristupa problemu segmentacije slike te se kao takve koriste za komparativnu evaluaciju kvalitete i efikasnosti predložene metode segmentacije. Obje pomenute metode implementirane su u obliku računalnog algoritma od strane samih autora, sa javno dostupnim programskim kodom. Korištenjem računalnog algoritma pripremljenog od strane autora metode osigurana je objektivnost evaluacije s obzirom na kvalitetu implementacije svake od ispitanih metoda.

Svi algoritmi primijenjeni su u $CIE L^*u^*v^*$ prostoru boja čija je osobina približna uniformnost, u smislu da udaljenosti među točkama odgovaraju perceptualnim razlikama među bojama koje su tim točkama predstavljene, približno uniformno na cijelom prostoru boja. Dodatno, analizirana je kvaliteta segmentacija dobivenih primjenom opisanih metoda direktno u RGB prostoru boja.

5.1 Procjena kvalitete

Procjena kvalitete rezultata dobivenih svakom od tri evaluirane metode temelji se na dva faktora: točnost i stabilnost. Pojam točnosti definiran je kao svojstvo algoritma da generira segmentacije koje su konzistentne sa *istinitim* segmentacijama koje su napravili ljudi, a mjeri se vrijednošću *NPR* indeksa. Drugi važan faktor koji definira kvalitetu algoritma je stabilnost. Može se argumentirati da algoritam kod kojeg su prosječni rezultati segmentiranja prihvatljive kvalitete, ali nepredvidivi s obzirom na slučajno odabranu sliku ili određen skup ulaznih parametara nije upotrebljiv kao dio kompleksnog sustava računalnog vida. U ovom slučaju, usprkos u prosjeku dobrim rezultatima, sustav koji bi koristio rezultate algoritma kao ulaz u više razine obrade ne može predvidjeti očekivanu razinu kvalitete dobivenih segmentacija. Pojam stabilnosti se iz ovog razmatranja može podijeliti na dva sastavna dijela: stabilnost s obzirom na upravljačke parametre algoritma i stabilnost s obzirom na različite slike.

Ispitani algoritmi segmentacije upravljani su jednim ili više upravljačkih parametara. Iako je smisao svakog od upravljačkih parametara za bilo koju od obrađenih metoda usko povezan sa nekim aspektom određivanja skale opservacije, točno značenje ovisi o metodi. Preliminarnim ispitivanjem, za svaku od evaluiranih metoda utvrđen je radni raspon svih ulaznih parametara, pri čemu su kao polazne vrijednosti korišteni rezultati sličnih istraživanja [73]. Za svaku od metoda, iz šireg intervala vrijednosti odabran je skup parametara takav da se prosječno najbolji rezultat za sve slike u *Berkeley Segmentation Dataset* bazi nalazi približno u sredini odabranog intervala upravljačkih parametara (slike 5.8, 5.9, 5.10, 5.11). U ostatku poglavlja prezentirani
su rezultati eksperimenata dobiveni primjenom radnog skupa upravljačkih parametara, koji je za sve evaluirane metode dan u tablici 5.1. Minimalna veličina segmenta slike je, u svim eksperimentima, za sve evaluirane metode, fiksirana na $\vartheta = 100$ piksela.

Metoda	Skup upravljačkih parametara
MS	$hr \in \{2, 3, 4, 6, 8, 10, 12, 14, 16\}, hs \in \{4, 8, 12, 16\}$
EGB	$\kappa \in \{25, 50, 75, 100, 125, 150, 175, 200, 225, 250, 275, 300\}$
AMBIS	$h_r^{(0)} \in \{2, 3, 4, 6, 8, 10, 12, 14, 16\}$
AMBIS+EGB	$h_r^{(0)} \in \{2, 3, 4, 6, 8, 10, 12, 14, 16\}, \kappa \in \{100, 200, 300\}$

Tablica 5.1: Skup upravljačkih parametara za svaku od metoda korišten u provedenim eksperimentima

U ostatku poglavlja prezentirani su rezultati komparativne evaluacije metoda segmentacije slike predstavljeni serijom dijagrama na kojima su istraženi razni aspekti problema procjene kvalitete i upotrebljivosti algoritma. Rezultati eksperimenata grupirani su prema određenom čimbeniku kvalitete dobivenih segmentacija. U svakoj skupini rezultata ciljano je zadržan isti raspon vrijednosti koordinatnih osi radi lakše međusobne usporedbe.

5.1.1 Najbolji rezultat

Ova serija eksperimenata provedena je sa ciljem utvrđivanja maksimalne kvalitete segmentacija koju svaka od promatranih metoda može ponuditi. Za svaku od slika u bazi prikazan je najbolji rezultat dobiven svakim od testiranih algoritama. Za svaku od metoda, rezultati su prikazani prema rastućem maksimalnom NPR indeksu, na način da prva slika (indeks i = 1 na apscisi) odgovara slici s najlošijim postignutim maksimalnim NPR indeksom za promatran algoritam. Isti indeks slike na apscisi ne predstavlja nužno istu sliku za različite algoritme.

Najbolji rezultat za sve algoritme prikazan je na slici 5.1. Može se zaključiti da za svaki od algoritama za većinu slika u bazi postoji kombinacija parametara koja daje koristan rezultat sa vrijednošću NPR indeksa većom od nula. Za mali broj slika, algoritmi MS i AMBIS postižu maksimalnu vrijednost NPR indeksa približno nula, dok kod EGB algoritma za neke od slike u bazi ne postoji kombinacija upravljačkih parametara koja bi rezultirala segmentacijom ocijenjenom pozitivnom vrijednošću NP indeksa. Najbolje rezultate daje MS algoritam, dok je najbolje ocijenjena segmentacija dobivena AMBIS algoritmom nešto lošija za većinu slika,



Slika 5.1: Maksimalni NPR indeks za sve kombinacije ulaznih parametara. Na slici (a) prikazani su rezultati za pojedinačne slike, poredani po rastućim vrijednostima NPR indeksa. Na slici (b) rezultati su prikazani u obliku histograma, pri čemu su na apscisi prikazane vrijednosti NPR indeksa, a na ordinati postotak slika za koji je postignut pripadajući NPR indeks

pri čemu su bolji rezultati dobiveni postprocesiranjem inicijalnih segmenata EGB algoritmom. Direktno primijenjen EGB algoritam daje najlošije rezultate.

5.1.2 Stabilnost s obzirom na upravljačke parametre



Slika 5.2: Srednji NPR indeks za sve kombinacije ulaznih parametara

Srednja vrijednost NPR indeksa za sve kombinacije ulaznih parametara prikazana je na slici 5.2. Razlika rezultata dobivenih MS i AMBIS algoritmom manja

je u odnosu na maksimalni NPR indeks što sugerira veću stabilnost s obzirom na ulazne parametre. Srednja vrijednost NPR indeksa segmentacija dobivenih AMBIS algoritmom ne razlikuje se značajno s obzirom na korištenu tehniku postprocesiranja u prostornoj domeni.

Na slici 5.3 zasebno su prikazani rezultati za svaku od testiranih metoda, pri čemu su u prvom retku prikazani rezultati za algoritma AMBIS sa jednostavnim postprocesiranjem stapanjem malih segmenata u prostornoj domeni, u drugom retku AMBIS+EGB, tj. algoritam AMBIS sa postprocesiranjem EGB algoritmom u prostornoj domeni. U trećem i četvrtom retku redom su dani rezultati za Mean Shift i EGB algoritam. U prvom stupcu prikazana je srednja vrijednost NPR indeksa i standardna devijacija ove vrijednosti za definirani skup ulaznih parametara. Manje oscilacije standardne devijacije oko srednje vrijednosti NPR indeksa znak su stabilnijeg ponašanja algoritma s obzirom na promjenu ulaznih parametara. Razdioba srednjih vrijednosti NPR indeksa za različite slike prikazana je histogramom u drugom stupcu, a grupiranje vrijednosti u desnom dijelu histograma označava bolji prosječni rezultat. Distribucija srednjih vrijednosti NPR indeksa pomaknuta je više u lijevo za EGB algoritam (4. redak), dok su za ostale metode rezultati slični, pri čemu je najbolji MS algoritam. Treći stupac prikazuje razdiobu standardne devijacije. Mala osjetljivost na izbor ulaznih parametara obilježena je grupiranjem vrijednosti u području manjih standardnih devijacije. Najveću osjetljivost na izbor parametara pokazuje MS algoritam. Usporedbom prvog i drugog retka slike 5.3 može se uočiti da je osjetljivost na izbor ulaznih parametara algoritma AMBIS manja u slučaju jednostavnijeg procesiranja u prostornoj domeni, dok se postprocesiranjem EGB algoritmom postiže nešto bolji prosječni rezultat.

Iz prethodne analize može se zaključiti da metoda srednjeg pomaka daje najbolje prosječne rezultate, ali uz najveću osjetljivost na izbor ulaznih parametara. Nešto su lošije prosječno ocijenjene segmentacije generirane metodom AMBIS, ali uz povećanu stabilnost algoritma s obzirom na ulazne parametre. Malu osjetljivost na izbor parametara pokazuje i EGB algoritam koji postiže prosječno najlošije rezultate.

Evaluirani algoritmi segmentacije nisu upravljani jednakim brojem parametara. Veće varijacije kvalitete dobivenih segmentacija MS metode dijelom se mogu objasniti i najvećim brojem kombinacija ulaznih parametara. Naime, ovaj algoritam upravljan je sa dva parametra: spektralnom pojasnom propusnosti (domena boja) h_r i prostornom pojasnom propusnosti (prostorna domena) h_s , sa ukupno 36 različitih kombinacija. S druge strane, performanse algoritma AMBIS testirane su za 9 vrijednosti jednog, ili 27 kombinacija dva upravljačka parametra u složenijoj varijanti postprocesiranja u prostornoj domeni. Samo jedan parametar koristi se i u EGB algoritmu.

Sa ciljem točnijeg utvrđivanja osjetljivosti svake od metoda na promjenu vrijednosti pojedinog parametra, provedena je detaljnija analiza. U svakoj seriji eksperimenata, ispitana je osjetljivost jedne od metoda na pojedini parametar, pri čemu su ostali upravljački parametri algoritma, ako ih ima, postavljeni na fiksnu vrijednost.

AMBIS: Osjetljivost na ulazne parametre

U prvoj seriji, ispitana je osjetljivost algoritma AMBIS na parametar $h_r^{(0)}$. Rezultati prikazani na slici 5.4 organizirani su na sljedeći način: U prvom retku prikazana je srednja vrijednost i standardna devijacija NPR indeksa dobivena osnovnom verzijom algoritma za sve vrijednosti parametra $h_r^{(0)}$. U drugom, trećem i četvrtom retku prikazani su rezultati AMBIS algoritma sa postprocesiranjem EGB metodom u prostornoj domeni, pri čemu je vrijednost parametra κ fiksirana redom na $\kappa = 100, \kappa = 200, \kappa = 300$. Kako je $h_r^{(0)}$ jedini upravljački parametar osnovne verzije algoritma, prvi redak slike 5.4 odgovara prvom retku slike 5.3, a rezultati su ovdje ponovljeni radi usporedbe sa rezultatima dobivenim EGB postprocesiranjem u prostornoj domeni.

Osjetljivost na parametar $h_r^{(0)}$ smanjuje se postprocesiranjem *EGB* algoritmom, ali samo za manje vrijednosti parametra κ . U odnosu na osnovnu verziju, algoritam se stabilnije ponaša za $\kappa \in [100, 200]$, a za ove vrijednosti parametra κ prosječna kvaliteta dobivenih segmentacija je najviša. Za $\kappa = 300$ prosječna vrijednost *NPR* indeksa opada, uz veću standardnu devijaciju oko srednje vrijednosti (veća osjetljivost na $h_r^{(0)}$).

U drugoj seriji, ispitana je osjetljivost algoritma AMBIS+EGB na izbor parametra κ . Na slici 5.5 prikazana je srednja vrijednost i standardna devijacija NPRindeksa za segmentacije dobivene korištenjem $\kappa \in \{100, 200, 300\}$, uz fiksnu vrijednost $h_r^{(0)}$. Radi preglednosti slika 5.5 ne uključuje rezultate za sve korištene vrijednosti $h_r^{(0)}$, a prikazani rezultati dovoljni su za uočavanje trenda.

Za veće vrijednosti pojasne propusnosti $h_r^{(0)}$ povećava se skala opservacije, uz opadanje broja finijih detalja otkrivenih filtriranjem u domeni boja. Preslikavanje klastera domene boja u prostornu domenu slike za rezultat ima inicijalnu segmentaciju sa manjim brojem detalja u finijoj skali i manju osjetljivost na metodu postprocesiranja. U skladu s prethodnim razmatranjem, osjetljivost rezultata na parametar κ manja je za veću pojasnu propusnost. S druge strane, za $h_r^{(0)} > 10$ prosječna kvaliteta dobivenih segmentacija opada, a optimalan odnos kvalitete rezultata i stabilnosti s obzirom na parametar κ dobiva se za $h_r^{(0)} \in [6, 10]$.

MS: Osjetljivost na ulazne parametre

U ovoj seriji eksperimenata ispitana je osjetljivost metode srednjeg pomaka na dva upravljačka parametra algoritma. Na slici 5.6 prikazani su prosječna kvaliteta segmentacija i standardna devijacija za različite vrijednosti parametra h_s , uz $h_r = 2, 4, 6, 10, 16$, redom od vrha prema dnu. Stabilnost s obzirom na parametar h_s je veća za manje vrijednosti h_r . Optimalan odnos srednje kvalitete i stabilnosti s obzirom na parametar h_s dobiva se izborom h_r iz raspona $h_r \in [6, 10]$.

Slika 5.7 dobivena je fiksiranjem $h_s = 4, 8, 12, 16$, redom od vrha prema dnu, uz variranje parametra h_r . Osjetljivost na parametra h_r smanjuje se za veći h_s . Prema slici 5.7, optimalan odnos kvalitete i stabilnosti MS algoritma dobiva se za srednje vrijednosti parametra h_s , u rasponu od $h_s = 8$ do $h_s = 12$.

EGB: Osjetljivost na parametar κ

EGB metoda segmentacije ima samo jedan upravljački parametar, a srednja kvaliteta i stabilnost dobivenih rezultata prikazana je četvrtim retkom slike 5.3. Ova metoda u prosjeku daje lošije rezultate u usporedbi s preostala tri algoritma. Stabilnost rezultata s obzirom na ulazni parametar je za većinu slika dobra, dok za manji broj slika kvaliteta značajnije ovisi o parametru κ , što rezultira uočljivim tragom u distribuciji standardnih devijacije prema desnoj strani histograma.

5.1.3 Stabilnost algoritma s obzirom na različite slike

Posljednja serija eksperimenata u ovoj skupini provedena je sa ciljem utvrđivanja stabilnosti kvalitete dobivenih segmentacija za različite slike. Stabilnost svih metoda ispitana je za svaku kombinaciju ulaznih parametara, a dobiveni rezultati prikazani su na slikama 5.8 do 5.11.

Rezultati za AMBIS algoritam sa stapanjem malih segmenata u prostornoj domeni dani su na slici 5.8. Krivulja prikazuje prosječnu vrijednost NPR indeksa za sve slike te jednu standardnu devijaciju, za različite vrijednosti parametra $h_r^{(0)}$ dane na apscisi. Prosječna vrijednost NPR indeksa raste za veći $h_r^{(0)}$, do $h_r^{(0)} = 10$, nakon čega prosječna kvaliteta dobivenih segmentacija opada. Ujednačenost kvalitete dobivenih segmentacija za različite slike bolja je za manje vrijednosti $h_r^{(0)}$. Optimalan odnos kvalitete i stabilnost nalazi se u rasponu $h_r^{(0)} = 8$ do $h_r^{(0)} = 10$.

Na slici 5.9 dani su rezultati za *AMBIS* algoritam sa *EGB* postprocesiranjem u prostornoj domeni. Rezultati su prikazani za sve kombinacije ulaznih parametara na način da su prikazani (a) rezultati sa parametrom κ fiksiranim na $\kappa = 100$; (b)

rezultati za $\kappa = 200$; (c) rezultati za $\kappa = 300$. Dobiveni rezultati slični su za sve tri vrijednosti κ . Za $\kappa = 300$ prosječna vrijednost NPR indeksa lošija je za male vrijednosti parametra $h_r^{(0)}$, dok u srednjem području ($h_r^{(0)} \in [6, 12]$) daje nešto bolje rezultate. Standardna devijacija uvijek raste za veće vrijednosti parametra $h_r^{(0)}$.

Srednja vrijednost NPR indeksa segmentacija svih slika u bazi dobivenih MSalgoritmom i standardna devijacija oko ove vrijednosti dana je na slici 5.10. Prikazani su redom rezultati za (a) $h_s = 4$, (b) hs = 8, (c) $h_s = 12$, (c) $h_s = 16$. Može se uočiti da se za veće vrijednosti parametra h_s maksimum krivulje miče u desno, prema većim vrijednostima h_r , dok za $h_s = 4$ prosječna kvaliteta rezultata oštrije opada za veće vrijednosti h_r . Spektralna i prostorna pojasna propusnost usko su povezane, a odnos ove dvije vrijednosti određuje izotropnost prostora u kojem se odvija filtriranje metodom srednjeg pomaka. *Mean Shift* daje prosječno najbolje rezultate u odnosu na ostale metode. Vrijednosti upravljačkih parametara su korelirane, pri čemu je osjetljivost na parametar h_s manja u odnosu na h_r . Optimalne vrijednosti parametara nalaze se u rasponu $h_s \in [8, 16], \quad h_r \in [6, 12].$

Najlošiju prosječnu vrijednost NPR indeksa postiže EGB metoda. Rezultati za različite vrijednosti parametra κ prikazani su na slici 5.11. Optimalna vrijednost parametra kreće se oko $\kappa = 100$. Za veće vrijednosti parametra opada prosječna kvaliteta dobivenih segmentacija, a stabilnost rezultata s obzirom na različite slike se smanjuje.



Slika 5.3: Osjetljivost algoritama na izbor ulaznih parametara. S lijeva na desno su za svaku od evaluiranih metoda prikazani: (1) srednja vrijednost NPR indeksa za sve kombinacije ulaznih parametara i jedna standardna devijacija oko srednje vrijednosti; (2) histogram distribucije srednjih vrijednosti NPRindeks; (3) distribucija standardnih devijacija. Po retcima su redom prikazani rezultati za sljedeće metode: AMBIS, AMBIS sa EGB postprocesiranjem u prostornoj domeni, metoda srednjeg pomaka (Mean shift), EGB metoda.



Slika 5.4: AMBIS: osjetljivost na parametar $h_r^{(0)}$. Od vrha prema dnu redom su prikazani rezultati za (1) AMBIS; (2) AMBIS+EGB, $\kappa = 100$; (3) AMBIS+EGB, $\kappa = 200$; (4) AMBIS+EGB, $\kappa = 300$



Slika 5.5: *AMBIS+EGB:* osjetljivost na parametar κ . Od vrha prema dnu redom su prikazani rezultati sa parametrom $h_r^{(0)}$ fiksiranim na vrijednosti $h_r^{(0)} = 2, 4, 6, 10, 16$.



Slika 5.6: MS: osjetljivost na parametar h_s . Od vrha prema dnu redom su prikazani rezultati sa parametrom h_r fiksiranim na vrijednosti $h_r = 2, 4, 6, 10, 16$.



Slika 5.7: MS: osjetljivost na parametar h_r . Od vrha prema dnu redom su prikazani rezultati sa parametrom h_s fiksiranim na vrijednosti $h_s = 4, 8, 12, 16$.



Slika 5.8: AMBIS- srednjiNPRza sve slike za različite vrijednosti parametra $h_r^{(0)}$



Slika 5.9: AMBIS+EGB- srednjiNPR indeks za sve slike za različite vrijednosti parametra $h_r^{(0)}$



Slika 5.10: $M\!S$ - srednjiNPRindeks za sve slike za različite vrijednosti parametra h_r



Slika 5.11: EGB- srednji NPRza sve slike za različite vrijednosti parametra κ

5.2 Efikasnost



Slika 5.12: Prosječno vrijeme izvršavanja za različite metode. Vrijeme izvršavanja prikazano je u logaritamskoj skali.

Efikasnost svakog od algoritama u ovisnosti o upravljačkim parametrima prikazana je slikom 5.12. Redom su dani rezultati za (a) AMBIS algoritam, (b) AM-BIS+EGB algoritam, (c) MS algoritam i (d) EGB algoritam, pri čemu je prikazano prosječno vrijeme izvršavanja za sve slike u bazi, za sve kombinacije ulaznih parametara. Prosječno vrijeme izvršavanja dano je u logaritamskoj skali. Za osnovnu varijantu algoritma AMBIS i EGB algoritam, koji su upravljani samo jednim parametrom, vremena izvršavanja dana su jednom krivuljom. U dva preostala slučaja, rezultati su prezentirani na način da je svaka od krivulja predstavlja efikasnost sa jednim od parametara postavljenim na fiksnu vrijednost. Na svim krivuljama, vrijednost na ordinati predstavlja ukupno vrijeme izvršavanja u sekundama, sa uključenim ulazno-izlaznim operacijama.

Ovisnost efikasnosti o ulaznim parametrima algoritma za svaku od metoda za-



Slika 5.13: AMBIS - vrijeme izvršavanja u ovisnosti parametru $h_r^{(0)}$

sebno prikazana je na slikama 5.13 do 5.16. Na slici 5.13 dana su prosječna vremena izvršavanja AMBIS algoritma u ovisnosti o parametru $h_r^{(0)}$. Za veće vrijednosti parametra, efikasnost se povećava, kao direktna posljedica manjeg broja ćelija trodimenzionalnog histograma. Ukupno vrijeme izvršavanja algoritma kreće se od 0.15 sekundi za $h_r^{(0)} = 16$ do nešto više od 0.7 sekundi za $h_r^{(0)} = 2$. Slična vremena izvršavanja ima i AMBIS+EGB algoritam, prikazan na slici 5.14, pri čemu trajanje ne ovisi bitno o parametru κ .

Trajanje MS algoritma za razne kombinacije ulaznih parametara dano je na slici 5.15, a veća računalna složenost metode rezultira dužim vremenom obrade. Trajanje obrade značajno ovisi o prostornoj pojasnoj propusnosti h_s , dok je ovisnost o spektralnoj pojasnoj propusnosti h_r manja. Vremena izvršavanja implementacije efikasne metode segmentacije particioniranjem grafa u ovisnosti o parametru κ dana su na slici 5.16. Prosječno vrijeme izvršavanja ne ovisi značajnije o parametru, osim za male vrijednosti parametra za koje se blago povećava.

Posljednja serija eksperimenata ispituje efikasnost u ovisnosti o dimenzijama ulazne slike. U ovu svrhu stvorena je baza slika podijeljenih u četiri skupine, po deset slika u svakoj skupini. Dimenzije slika u pojedinoj skupini redom su $481 \times 321,750 \times 563,1600 \times 1200,2048 \times 1536$. Na ovoj bazi slika pokrenuti su evaluirani algoritmi segmentacije. Vrijednosti upravljačkih parametara svakog algoritma uzete su iz sredine optimalnog raspona vrijednosti parametara dobivenih



Slika 5.14: AMBIS+EGB- prosječno vrijeme izvršavanja za sve kombinacije ulaznih parametara $h_r^{(0)}$ i κ

Algoritam	Optimalni parametri	Korištena vrijednost
AMBIS	$h_r^{(0)} \in [6, 10]$	$h_r^{(0)} = 8$
AMBIS+EGB	$h_r^{(0)} \in [6, 10], \kappa \in [100, 300]$	$h_r^{(0)} = 8, \kappa = 200$
MS	$h_s \in [8, 12], h_r \in [6, 10]$	$h_s = 8, h_r = 8$
EGB	$\kappa \in [50, 150]$	$\kappa = 100$

Tablica 5.2: Vrijednosti upravljačkih parametara

analizom u poglavlju 5.1. Raspon upravljačkih parametara za sve algoritme i odabrana vrijednost dani su u tablici 5.2.

Rezultati eksperimenta prikazani su na slici 5.17 u logaritamskoj skali, pri čemu su na apscisi navedene dimenzije slika, a na ordinati prosječno vrijeme segmentiranja slike svakim od algoritama. Vrijeme obrade za sva četiri algoritma približno je linearno broju piksela slike, tj. složenost svih metoda je približno O(N), gdje je Nbroj piksela slike, pri čemu najmanji koeficijent složenosti ima algoritam AMBIS.



Slika 5.15:MS- prosječno vrijeme izvršavanja za sve kombinacije spektralne pojasne propusnosti h_r i prostorne pojasne propusnosti h_s



Slika 5.16:EGB- prosječno vrijeme izvršavanja u ovisnosti o parametru κ



Slika 5.17: Srednje vrijeme izvršavanja u ovisnosti o dimenzijama. Za svaku od metoda korišteni su parametri iz sredine optimalnog intervala. Za MS algoritam odabrane vrijednosti parametara h_s, h_r nalaze se na donjoj granici optimalnog intervala, dok se za više vrijednosti dobivaju duža vremena obrade.



5.3 Primjena u *RGB* prostoru boja

Slika 5.18: Kvaliteta rezultata dobivena primjenom metoda segmentacije u RGB prostoru boja: (a) maksimalna vrijednost NPR indeksa, (b) srednja vrijednost NPR indeksa

Učinkovitost metoda temeljenih na analizi prostora značajki uvelike ovisi o primijenjenoj metrici. Ove se metode oslanjaju na pretpostavku uniformnosti prostora, u smislu kvantitativno jednake udaljenosti među perceptualno jednako različitim bojama na cijeloj domeni (poglavlje 2.1). U svim dosad prikazanim eksperimentima, istražena je učinkovitost predložene metode segmentacije, kao i metoda korištenih za komparativnu evaluaciju, u $L^*u^*v^*$ prostoru boja. Ovaj prostor boja povezan je sa RGB prostorom nelinearnim transformacijama (tablica 2.1), a približno zadovoljava uvjet uniformnosti. U ostatku poglavlja ispitana je mogućnost primjene opisanih metoda segmentacije direktno u RGB prostoru boja, a kratka analiza dobivenih rezultata prikazana je na slici 5.18.

Na slici 5.18(a) prikazan je najbolji rezultat za svaku od metoda primijenjenu u RGB prostoru boja. Rezultati su prikazani sa rastućim NPR indeksom, pri čemu isti indeks slike na apscisi ne mora nužno predstavljati istu sliku za sve algoritme. Prosječan rezultat za razne kombinacije upravljačkih parametara, prikazan prema rastućoj vrijednosti srednjeg NPR indeksa, dan je slici 5.18(b). Može se uočiti da su najbolji rezultati za sve metode lošiji u odnosu na rezultate dobivene implementacijom u $L^*u^*v^*$ prostoru boja. U slučaju primjene u RGB prostoru, metode AMBIS i MS daju gotovo jednako kvalitetne rezultate. Manja razlika u kvaliteti segmentacija generiranih AMBIS i MS metodama primijenjenima u RGB prostoru u odnosu na rezultate dobivene u približno uniformnom $L^*u^*v^*$ prostoru može se objasniti korištenjem jezgre adaptivne pojasne propusnosti u AMBIS metodi, čime je djelomično kompenzirana neuniformnost prostora boja. Karakteristika EGB metode segmentacije je mala osjetljivost na upravljačke parametre, što se manifestira

malom razlikom prosječno ostvarenog i najboljeg NPR indeksa u RGB prostoru. Dodatno, prosječna kvaliteta segmentacija dobivenih EGB metodom ne razlikuje se značajno od kvalitete segmentacija dobivenih sa preostale dvije metode, kada se metode segmentacije primjene direktno u RGB prostoru.

Ova kratka analiza sugerira mogućnost primjene metoda segmentacije u *RGB* prostoru, uz nešto nižu očekivanu kvalitetu rezultata. S druge strane, predstavljanje informacije o boji u obliku iznosa podražaja *crvene, zelene* i *plave* komponente najčešći je format zapisa boje i uobičajeni način kodiranja video informacije od strane uređaja za dohvat slike, te se primjenom algoritama segmentacije slike direktno u *RGB* prostoru, bez transformacije u neki drugi prostor boja, može očekivati povećanje efikasnost obrade, bez obzira na odabranu metodu segmentacije.

5.4 Ovisnost rezultata o funkciji jezgre



Slika 5.19: Usporedba rezultata dobivenih korištenjem normalne i Epanechnikove jezgre: (a) maksimalna vrijednost NPR indeksa, (b) srednja vrijednost NPR indeksa.

Ovisnost kvalitete segmentacija dobivenih AMBIS metodom o funkciji jezgre prikazana je na slici 5.19. Maksimalni NPR indeks prikazan je slici 5.19(a), dok je srednja vrijednost indeksa za sve vrijednosti parametra $h_r^{(0)}$ dana slici 5.19(b). Prikazani su rezultati dobiveni korištenjem Epanechnikove (3.10) jezgre, koja je implementirana u osnovnoj verziji algoritma i primjenjena u svim ostalim eksperimentima, i normalne (3.12) jezgre. Pri provođenju eksperimenta, svi dijelovi algoritma, osim same funkcije za računanje doprinosa uzorka jezgrom, bili su jednaki. Dobiveni rezultati gotovo su u potpunosti jednaki s obzirom na srednju i maksimalnu



vrijednostNPRindeksa za različite vrijednosti upravljačkog parametra $h_r^{(0)}.$

Slika 5.20: Usporedba rezultata dobivenih korištenjem normalne i Epanechnikove jezgre za različite vrijednosti parametra $hr^{(0)}$

Na slici 5.20 prikazani su rezultati za dvije fiksne vrijednosti parametra $h_r^{(0)}$. Fiksiranjem vrijednosti upravljačkog parametra dobija se jasniji uvid u ovisnost rezultata algoritma o primijenjenoj jezgri. Ni u ovom slučaju gotovo da nema odstupanja u kvaliteti dobivenih segmentacija te se može zaključiti da izbor jezgre ne utječe značajnije na predloženu metodu segmentacije.

Poglavlje 6

Optimizacija asinkronim PRAM modelom

U ovom poglavlju istražena je mogućnost povećanja efikasnosti predložene metode segmentacije implementacijom algoritma u paralelnom modelu računanja. Motivacija za razvoj paralelne implementacije algoritma segmentacije slike temelji se na tehnološkim karakteristikama modernog računalnog sklopovlja sa mogućnošću višestrukih linija izvršavanja. Cilj prilagodbe predložene metode segmentacije paralelnoj paradigmi je optimizacija ključnih djelova koda kroz učinkovitije korištenje računalnih resursa. Povećanjem efikasnosti algoritma, uz zadržavanje jednake razine kvalitete, širi se spektar problema na koje je predloženo rješenje moguće primijeniti.

Prezentirani su rezultati eksperimentalne analize složenosti pojedinih faza obrade, sa ciljem izdvajanja djelova algoritma čijom bi se optimizacijom moglo značajnije utjecati na efikasnost. Rezultati dobiveni eksperimentalnom analizom u skladu su sa teoretskom analizom složenosti danom u poglavlju 3.5. Uočeni koraci algoritma segmentacije sa najdužim vremenom izvršavanja optimirani su prema asinkronom paralelnom modelu računanja. Ostatak poglavlja organiziran je na slijedeći način: U poglavlju 6.1 izložene su osnovne paralelne paradigme. Analiza složenosti pojedinih faza algoritma segmentacije i implementacija ključnih koraka u paralelnoj paradigmi opisana je u poglavlju 6.2. U poglavlju 6.3 prezentirani su rezultati analize efikasnosti paralelne implementacije AMBIS metode segmentacije slike.

6.1 Paralelno računanje

Osnovni cilj razvoja paralelnih modela računanja je rješavanje problema u manje vremena nego što bi zahtijevalo slijedno računanje. Usprkos brzom razvoju računalnog sklopovlja, težnja za rješavanjem novih i sve složenijih problema, ali i dobivanjem preciznijih rješenja postojećih problema, rezultira kontinuiranim rastom zahtjeva za većom računalnom moći. Neki od najzahtjevnijih računalnih problema uključuju kompleksna modeliranja i simulacije klimatskih, seizmičkih i drugih prirodnih pojava, simulacije kemijskih i tehnoloških procesa, analizu rezultata znanstvenih eksperimenata i obradu velikih tekstualnih i multimedijskih baza podataka. Posebnu skupinu čine problemi kod kojih se rješenje traži u stvarnom vremenu¹, pri čemu je često moguć interaktivan rad korisnika. Primjeri ovakvih sustava su pretraživanje Interneta i video serveri u stvarnom vremenu.

6.1.1 Paralelne paradigme

Paralelno računalo čini skup procesora koji mogu zajednički rješavati neki računalni problem. S obzirom na memorijsku strukturu, paralelna računala dijelimo na dva osnovna modela. U modelu dijeljene memorije više procesora radi nezavisno, ali koriste isti memorijski spremnik. Suprotno tome, u modelu distribuirane memorije, svaki je procesor opremljen neovisnim memorijskim spremnikom, a podatkovna komunikacija odvija se razmjenom poruka. Prema ovoj podjeli, definirane su i osnovne paradigme paralelnih algoritama:

- *Komunikacija porukama* više se zadataka izvodi neovisno, a podaci se razmjenjuju porukama. Ovo je možda i najčešće korišteni model paralelnog računala, implementiran je na brojnim platformama, a često se koristi za rješavanje numerički zahtjevnih znanstvenih problema [80, 82, 83]. Moguća je arhitektura kod koje se unutar unutar jedinstvenog programa implementiraju različite uloge u sustavu (*master-slave* model).
- *Podatkovni paralelizam* primjena iste operacije na više elemenata podatkovne strukture² [81, 82, 83].
- Zajednička memorija zadaci se odvijaju neovisno, a dijele isti memorijski spremnik. Ovaj model omogućava jednostavnije programiranje, ali zahtjeva eksplicitne mehanizme zaštite memorije.

Način rješavanja nekog problema paralelnim algoritmom ovisi o samom problemu i specifičnim zahtjevima. Osnovni zahtjev koji se postavlja pred problem segmentacije slike kao zadatak niske razine računalnog vida je kratko vrijeme obrade, tj. izvršavanje u stvarnom vremenu. Dodatno, poželjna je mogućnost implementacije algoritma na jednostavnom računalnom sklopovlju, što uključuje i uklopljena³ računala. Navedeni zahtjevi ograničavaju mogućnost paralelne implementacije algoritma segmentacije slike na model računala sa dijeljenom memorijom. Korištenjem paralelne paradigme sa zajedničkom memorijom zadržava se mogućnost implementacije algoritma na uklopljenim računalima, uz istovremeno izbjegavanje latencija

 $^{^{1}}real$ -time

²SIMD model (Single Instruction, Multiple Data)

 $^{^{3}}embedded$

koje mogu biti posljedica sporije komunikacije u sustavima sa razmjenom poruka.

6.1.2 Asinkrono paralelno računalo sa slučajnim pristupom

Najčešće korišteni model slijednog računala je računalo sa slučajnim pristupom RAM (Random Access Machine). Ovaj model ekvivalent je univerzalnog Turingovog stroja, a podrazumijeva konstantan broj registara i neograničen broj memorijskih lokacija čije su adrese prirodni brojevi [81]. Svaka operacija obavlja se u jednoj jedinici vremena, a svaka memorijska lokacija je jedna jedinica prostora. Idealizirana ekstenzija RAM modela na paralelnu paradigmu opisana je PRAM (Parallel Random Access Machine) [81, 82, 84, 85] modelom računala. PRAM model ima proizvoljan broj procesora koji dijele zajedničku memoriju. Računalo je sinkrono u smislu da svi procesori izvode jednu instrukciju u jednoj jedinici vremena (režim zaključanih koraka⁴), pri čemu razni procesori mogu izvršavati različite instrukcije⁵. Svi algoritmi razvijeni za PRAM model instrukcije na različitim procesorima obavljaju u režimu zaključanih koraka, pri čemu se pretpostavlja jednaki trošak pristupa memoriji za bilo koju memorijsku lokaciju.

Sinkroni PRAM model predstavlja apstrakciju paralelnog računala, bez razmatranja aspekata kao što su sinkronizacija procesa, latencija i konflikti u pristupu memoriji, a u praksi nije realizirano računalo prema predloženom modelu [84]. Bliži stvarnim računalima je model asinkronog paralelnog računala sa zajedničkom memorijom APRAM [81]. Asinkroni PRAM model definiran je na sljedeći način:

- Računalo se sastoji od više procesora, od kojih svaki ima lokalnu memoriju, a svima je na raspolaganju globalna memorija.
- Svaki procesor izvodi svoj program neovisno o drugima (procesori međusobno nisu sinkronizirani).
- Razlikujemo globalne (čitanje, pisanje) i lokane operacije, te operaciju sinkronizacije.
- lokalni programi čini niz asinkronih odsječaka odvojenih sinkronizacijskim ogradama. Zadnja instrukcija u svakom programu uvijek je ograda.
- Procesori mogu asinkrono pristupati globalnoj memoriji, ali samo jedan procesor može pristupiti istoj globalnoj memorijskoj lokaciji unutar istog asinkronog odsječka.

 $^{^4}lock\ step$

⁵MIMD model (Multiple Instruction, Multiple Data)

Algoritmi razvijeni prema asinkronom *PRAM* modelu mogu se izvršavati i na platformama kod kojih broj fizičkih procesora ne mora nužno odgovarati broju procesa koje program koristi, sve dok arhitektura dopušta mogućnost izvršavanja više asinkronih procesa u dijeljenom vremenu⁶. U ovom slučaju, povećanje efikasnosti ostvaruje se kao posljedica različitih zadaća (npr. računanje sa pomičnim zarezom i pristup memoriji) koje procesi obavljaju u istom vremenskom odsječku te postojanja višestrukih paralelnih podsustava obrade u modernom računalnom sklopovlju.

6.2 Optimizacija algoritma segmentacije asinkronom PRAM paradigmom



Slika 6.1: Prosječno vrijeme izvršavanja pojedinih faza slijednog algoritma za različite vrijednosti parametra $h_r^{(0)}$

Funkcionalnom dekompozicijom i analizom pojedinih faza slijednog algoritma segmentacije mogu se izdvojiti koraci optimizacijom kojih bi se mogla značajnije povećati efikasnost. Na slici 6.1 prikazana je analiza trajanja pojedinih faza algoritma segmentacije. Prikazani su rezultati za tri različite vrijednosti parametra $h_r^{(0)}$, a analiza složenosti provedena je za osam osnovnih faza algoritma. Prvi i posljednji korak predstavljaju ulazne i izlazne operacije, pri čemu ulaz uključuje i

⁶time sharing

transformaciju u $CIE L^*u^*v^*$ prostor boja. Trajanje ove dvije faze ne ovisi o ulaznim parametrima. Drugi korak je izgradnja trodimenzionalnog adaptivnog histograma (algoritam 1) u $L^*u^*v^*$ prostoru boja, a trajanje ovog procesa značajno ovisi o granularnosti diskretizacije pa se za veće vrijednosti parametra trajanje faze povećava (složenost O(2N + (c+1)M), gdje je N broj piksela slike, M broj populiranih ćelija histograma te c konstanta koja ovisi o okolini u kojoj se doprinos računa). Pridruživanje oznaka pripadnosti (labeliranje) u domeni boja određivanjem dominantnih boja (algoritmi 3 i 2) predstavljeno je trećim korakom, a složenost (približno O(2M)) ponovo značajno ovisi o granularnosti histograma. Četvrti korak predstavlja preslikavanje klastera domene boja u prostornu domenu slike, što uključuje prolaz kroz sve piksele slike (složenost O(N)), i manje ovisi o ulaznom parametru. Iduća tri koraka odnose se na procesiranje u prostornoj domeni. Konstrukcija i sortiranje rubova grafa izdvojeno je kao zasebna faza koja se uvijek izvodi kao prvi korak u procesiranju inicijalnih segmenata bez obzira koristi li se EGB metoda, ili jednostavno povezivanje malih segmenata, a može se promatrati kao zasebna cjelina. Složenost postupka dobivanja finalne segmentacije ovisi o granularnosti segmenata dobivenih filtriranjem u domeni boja, gdje manja pojasna propusnost $h_r^{(0)}$ rezultira većim brojem manjih segmenata i većom količinom podataka za procesiranje u prostornoj domeni.

Rezultati dobiveni eksperimentalnom analizom složenosti pojedinih faza algoritma segmentacije u skladu su sa teoretskim predviđanjima. Računski najzahtjevniji dijelovi algoritma su konstrukcija histograma i preslikavanje klastera domene boja u prostornu domenu, kod kojih se pristupa svim pikselima slike. Podatkovnom dekompozicijom domene [82] skup podataka može se raščlaniti na podskupove čiju je obradu moguće na efikasan način provesti istovremeno, definiranjem zadataka koji su zaduženi za određeni dio podataka. Zadaci se izvršavaju neovisno, a sinkronizacija je nužna u točkama algoritma kod kojih daljnji tijek obrade ovisi o rezultatima svih zadataka. Identifikacijom ključnih koraka obrade velike računalne složenosti kod kojih je moguća dekompozicija domene, i implementacijom istih u *APRAM* paradigmi može se ostvariti povećanje efikasnosti obrade.

6.2.1 Diskretna aproksimacija gustoće u APRAM paradigmi

Postupak računanja diskretne aproksimacije gustoće prema asinkronom PRAM modelu dan je algoritmom 4. Opisani algoritam predviđen je za izvođenje na p+1 procesoru, pri čemu procesori P1 do Pp obavljaju računski dio algoritma, dok procesor P0 izvršava program koji upravlja globalnim parametrima algoritma. Izvođenje programa na različitim procesorima je neovisno, a odsječci koda odvojeni su sinkronizacijskim ogradama. Postupak računanja histograma podijeljen je u šest cjelina. Uvjet za početak izvršavanja svake od cjelina je završetak prethodne na svim procesorima. Prva, treća i peta cjelina odnose se učitavanje ulaznih podataka i postavljanje globalnih parametara algoritma kombiniranjem rezultata dobivenih na pojedinim procesorima, izvršavaju se na procesoru P0 za koje vrijeme ostali procesori čekaju na sinkronizacijskoj ogradi. U drugom, četvrtom i šetom odsječku procesori P1 do *Pp* vrše obradu pripadajućeg podskupa podataka, pri čemu pristupaju globalnoj i lokalnoj memoriji. U drugoj cjelini svaki od procesora P1 do Pp upisuje raspon lokalnih podataka u zaseban dio globalne memorije koje u idućoj fazi koristi procesor P0. U ovom postupku, ne dolazi do pristupa istim memorijskim lokacijama pa eksplicitna zaštita memorije nije potrebna. U postupku računanja inicijalnog (četvrta cjelina) i konačnog (šesta cjelina) histograma procesori P1 do Pp pristupaju globalnoj memoriji, pri čemu su mogući istovremeni zahtjevi za ažuriranjem iste memorijske lokacije (iste ćelije histograma) te je u ovom slučaju nužno osigurati eksplicitne mehanizme zaštite globalne memorije. Za vrijeme izvršavanje druge, četvrte i šeste cjeline procesor P0 čeka na sinkronizacijskoj ogradi. Zadnja instrukcija u svim programima je, sukladno modelu, sinkronizacijska ograda, nakon koje svi programi prekidaju izvršavanje, a konačni rezultat pohranjen je u globalnoj memoriji, tj. vraća se programskom modulu koji je pozvao paralelnu rutinu za računanje diskretne aproksimacije gustoće.

```
Algoritam 4 hist, nbins \leftarrow diskretna_gustoćaP(imgRGB, N, h_r^{(0)}, \rho, K(x), p)
```

- **Ulaz:** slika imgRGB, broj piksela N, fiksna pojasna propusnost $h_r^{(0)}$, faktor proporcionalnosti ρ , funkcija jezgre K(x), broj računskih procesa p (ukupan broj procesa je p + 1)
- Izlaz: diskretna aproksimacija gustoće hist, broj ćelija u svakoj dimenziji nbins

Globalna memorija: imgTRAN, chist, hist, nbins, min, max, locMin(p), locMax(p), N, locN, M, locM, σ

PROCESOR: P0

imgTRAN ← transformacija_boje(imgRGB)
 σ = h_r⁽⁰⁾/ρ
 locN = N/p
 - - sinkronizacija - - -

%% procesi 1 do p računaju interval pridruženog skupa podataka

```
- - - sinkronizacija - - -
```

```
4: min[1:3], max[1:3] \leftarrow globalni_interval(locMin, locMax)

5: nbins[1:3] \leftarrow (max[1:3] - min[1:3])/\sigma

6: chist(nbins[1] \cdot nbins[2] \cdot nbins[3]) \leftarrow 0
```

```
- - - sinkronizacija - - -
```

%%Inicijalna estimacija funkcije gustoće (proces
i $1~{\rm do}~{\rm p})$

```
7: --- sinkronizacija ---

8: n = 0

9: s = 0

10: for all chist[i] > 0 do

11: s = s + \ln(chist[i])

12: n = n + 1

13: end for

14: \lambda = \exp(s/n)

15: M = nbins[0] \cdot nbis[1] \cdot nbins[2]

16: locM = M/p

17: hist(nbins[1] \cdot nbins[1] \cdot nbins[2]) \leftarrow 0
```

```
- - - sinkronizacija - - -
```

%%procesi1do p
 računaju adaptivni histogram

- - - sinkronizacija - - -

18: return hist, nbins

PROCESOR: P1 - Pp

```
- - - sinkronizacija - - -
```

```
1: odN = (pID - 1) \cdot locN
```

- 2: $doN = \min(pID \cdot locN, N)$
- 3: $locMin[pID, 1 : 3], locMax[pID, 1 : 3] \leftarrow odredi_interval(imgTRAN[odN : doN])$

- - - sinkronizacija - - -

%%P0 određuje globalni interval i inicijalizira histogram

```
- - - sinkronizacija - - -
```

```
4: for i = odN : doN do
```

- 5: $pbin[1:3] \leftarrow (imgTRAN[i,1:3] min[i,1:3])/\sigma$
- $6: \quad chist[pbin] = chist[pbin] + 1$

7: end for

```
- - - sinkronizacija - - -
```

%% P0 računa geometrijsku sredinu i inicijalizira adaptivni histogram

```
- - - sinkronizacija - - -
```

```
8: odM = (pID - 1) \cdot locM
 9: doM = \min(pID \cdot locM, M)
10: for all chist[l] > 0 and odM \leq l < doM do
       h_r = h_r^{(0)} \cdot \sqrt{\lambda/chist[l]}
11:
       \tau = \rho \cdot \sqrt{\lambda/chist[l]}
12:
        c_l \leftarrow \text{koordinate\_centra}(chist[l])
13:
        for all hist[u] : c_u \leftarrow koordinate\_centra(hist[u]), \ d(c_u, c_l) \le \tau \sigma \ do
14:
           \hat{Z}(c_u, c_l) = chist[l] \cdot K\left(\frac{c_u - c_v}{h_r}\right) / h_r^3
15:
           hist[u] = hist[u] + \hat{Z}(c_u, c_l)
16:
        end for
17:
18: end for
      - - - sinkronizacija - - -
```

6.2.2 Preslikavanje klastera u prostornu domenu

P1

Preslikavanje klastera domene boja u prostornu domenu proces je koji rezultira inicijalnom segmentacijom slike, pri čemu broj segmenata slike može biti veći ili jednak broju klastera u domeni boja. Ovaj postupak jednostavno se realizira u asinkronoj *PRAM* paradigmi dekompozicijom slike na regije i istovremenim pokretanjem postupka preslikavanja zasebnim procesima u svakoj regiji slike. U ovom slučaju, jedinstveni segmenti koji se protežu preko granica područja zasebnih regija dijele se na više manjih segmenata (slika 6.2). Težina rubova među segmentima koji su nastali podjelom jedinstvenog segmenta kao posljedica dekompozicije domene postavlja se na nulu. Ovi segmenti se u cjeline povezuju nakon što svi procesi završe obradu pripadajućeg dijela slike postprocesiranjem u prostornoj domeni.



Slika 6.2: Paralelno preslikavanje klastera domene boja u prostornu domenu podatkovnom dekompozicijom slike. Podjelom slike po visini i preslikavanjem sa dva procesa rezultira vertikalnom podjelom jedinstvenih segmenata.

6.3 Analiza efikasnosti paralelnog algoritma

Implementacijom postupka računanja diskretne aproksimacije gustoće i postupka preslikavanja klastera domene boja u domenu slike prema *APRAM* modelu optimirani su ključni dijelovi algoritma segmentacije. Analiza trajanja pojedinih faza algoritma pokrenutog sa 2, 4 i 8 istovremenih niti izvršavanja dana je na slikama 6.3, 6.4 i 6.5. Na slici 6.3 prikazana su vremena izvršavanja koraka algoritma za dvije



Slika 6.3: Prosječno vrijeme izvršavanja pojedinih faza algoritma za različite vrijednosti parametra $h_r^{(0)}$. Ključni koraci realizirani su u *APRAM* paradigmi sa dvije niti izvršavanja.

paralelne asinkrone niti. Vrijeme računanja adaptivnog histograma je 25 - 30 posto kraće u odnosu na implementaciju sa slijednim izvršavanjem, pri čemu se veća ubrzanja dobivaju za finiju granulaciju domene boja (manji parametar $h_r^{(0)}$). Za veći broj niti efikasnost postupka računanja histograma dodatno se povećava, pa je tako za 4 niti (slika 6.4) moguće ubrzanje do 40%, dok je za 8 niti (slika 6.5) vrijeme računanja histograma i do 50% kraće u odnosu na algoritam sa slijednim izvršavanjem. Ostvareno povećanje efikasnosti manje je za postupak preslikavanja klastera domene boja u prostornu domenu slike i može iznositi do 25%, a ne ovisi značajnije o broju niti. Postupak dekompozicije slike na regije pri preslikavanju klastera u domenu slike može za rezultat imati podjelu jedinstvenih segmenata na dijelove (slika 6.2), pri čemu je težina rubova među dijelovima jedinstvenog segmenta jednaka nuli. Ovi segmenti se povezuju u cjeline postprocesiranjem u prostornoj domeni, a veći broj segmenata rezultira nešto dužim trajanjem posljednjeg koraka obrade, koji prethodi izlaznoj operaciji snimanja dobivene konačne segmentacije, kod kojeg se povezuju mali segmenti i segmenti sa težinom ruba jednakom nuli.

Prosječno vrijeme obrade svih slika za različite vrijednosti parametra $h_r^{(0)}$ dano je na slici 6.6. Redom su prikazana vremena izvršavanja: (a) slijednog algoritma, (b) paralelnog algoritma sa dvije niti izvršavanja, (c) algoritma sa 4 niti izvršavanja i (d) osam niti izvršavanja. Vrijeme obrade algoritma sa ključnim dijelovima napravljenim u *APRAM* paradigmi kraće je do 20% u odnosu na slijednu verziju algo-



Slika 6.4: Prosječno vrijeme izvršavanja pojedinih faza algoritma za različite vrijednosti parametra $h_r^{(0)}$. Ključni koraci realizirani su u *APRAM* paradigmi sa četiri niti izvršavanja.

ritma. Ova analiza odnosi se na ukupno vrijeme izvršavanja algoritma što uključuje i ulazno-izlazne operacije, dok se povećanje efikasnosti samog postupka segmentacije kreće do 30%. Slična ubrzanja ostvarena su za algoritma segmentacije sa korištenjem EGB postprocesiranja u prostornoj domeni, čiji su rezultati prikazani slikom 6.7.



Slika 6.5: Prosječno vrijeme izvršavanja pojedinih faza algoritma za različite vrijednosti parametra $h_r^{(0)}$. Ključni koraci realizirani su u *APRAM* paradigmi sa osam niti izvršavanja.



Slika 6.6: Prosječno vrijeme obrade algoritma AMBIS za različite kombinacije ulaznih parametara. Prikazano je prosječno trajanje obrade za: (a) algoritam sa slijednim izvršavanjem, algoritam optimiran prema *asinkronom PRAM* modelu, sa (b) dvije, (c) četiri i (d) osam niti izvršavanja ključnih koraka.



Slika 6.7: Prosječno vrijeme obrade algoritma AMBIS sa EGB postprocesiranjem u prostornoj domeni, za različite kombinacije ulaznih parametara. Prikazano je prosječno trajanje obrade za: (a) algoritam sa slijednim izvršavanjem, algoritam optimiran prema *asinkronom PRAM* modelu, sa (b) dvije, (c) četiri i (d) osam niti izvršavanja ključnih koraka. U odnosu na slijedni algoritam, efikasnost je povećana do 20%. Povećanje efikasnosti samog postupka segmentacije, bez uključenih ulazno-izlaznih operacija je do 30%.
Poglavlje 7

Adaptivno filtriranje i primjena u sustavu protupožarnog nadzora

U ovom poglavlju opisana je primjena predložene metode segmentacije u sustavu protupožarnog nadzora korištenjem video kamera u vidljivom dijelu spektra. Opisana metoda koristi se za konstrukciju adaptivnog niskopropusnog filtra čijom primjenom se sa slika uklanjaju smetnje bez gubitka informacije o granicama područja. Konstrukcije adaptivnog filtra opisana je u poglavlju 7.1, sa primjerima primjene filtra, dok je način korištenja u sustavu za detekciju dima opisan u poglavlju 7.2.

7.1 Adaptivno filtriranje

Niskopropusni filter realizira se konvolucijom ulazne slike sa uniformnim filtrom, a rezultira zaglađivanjem detalja slike. Vrijednost piksela izlazne slike dobiva se kao suma produkta piksela ulazne slike i diskretne jezgre, pri čemu se za jezgru najčešće koristi kvadratna matrica neparne dimenzije. Ovaj postupak ilustriran je slikom 7.1(a). Vrijednost piksela izlazne slike dobivena je korištenjem jezgre dimenzija 5×5 , zadane sa:

Korištenjem fiksne jezgre rezultirajuća slika dobiva se usrednjavanjem susjedstva svakog piksela slike, pri čemu se ne vodi računa o granicama objekata na slici, što može rezultirati zamućivanjem rubova i gubitkom dijela ulazne informacije.

Alternativni pristup, temeljen na korištenju adaptivne diskretne jezgre, ilustiran je slikom 7.1(b). Oblik jezgre adaptivno se određuje za svaki piksel slike, prema granicama zasebnih regija na sceni detektiranih *AMBIS* metodom segmentacije. Pikseli izlazne slike dobivaju se usrednjavanjem susjedstva promatranog piksela, pri čemu se u obzir uzimaju samo susjedni pikseli koji su dio istog segmenta na ulaznoj slici. Na slici 7.1(b) ilustrirano je formiranje jezgre u blizini granice dvije zasebne regije na ulaznoj slici, a rezultirajuća vrijednost izlaznog piksela slike dobivena je konvolucijom sa jezgrom:

-

$$K_A = \frac{1}{18} \begin{vmatrix} 1 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 1 & 1 \\ 0 & 0 & 0 & 1 & 0 \end{vmatrix}$$
(7.2)

Adaptivnim filtriranjem slike smanjuje se količina detalja i eventualnih smetnji, uz očuvanje informacije o granicama objekata na slici. Nužan preduvjet za implementaciju adaptivnog filtra je učinkovit način računanja segmentacije ulazne slike.

Primjeri adaptivnog filtriranja implementiranog korištenjem AMBIS metode segmentacije i adaptivne jezgre dani su na slikama 7.2, 7.3 i 7.4. Na slikama su prikazani različiti motivi, a redom su prikazani (a) ulazna slika, (b) slika filtrirana fiksnom jezgrom te (c) slika filtrirana adaptivnom jezgrom. Rezultat filtriranja usrednjavanjem je ublažavanje finih tekstura, na primjer krzna životinje (slika 7.2) ili površine kamena (slike 7.3 i 7.4). Kod slika filtriranih fiksnom jezgrom uočljivo je zamućenje slike i gubitak jasnih granica. S druge strane, filtriranjem adaptivnom jezgrom, granice među objektima na slici dodatno su istaknute.



Slika 7.1: Konvolucija slike: (a) fiksnom jezgrom, rezultirajuća vrijednost promatranog piksela dobija se usrednjavanjem svih susjeda; (b) adaptivnom jezgrom, rezultirajuća vrijednost dobija se usrednjavanjem susjeda koji pripadaju istom segmentu ulazne slike.



(a)



(b)



(c)

Slika 7.2: Adaptivno filtriranje: (a) ulazna slika, (b) filtrirana slika, (c) slika filtrirana primjenom adaptivnog filtra





(c)

Slika 7.3: Adaptivno filtriranje: (a) ulazna slika, (b) slika filtrirana korištenjem fiksne jezgre, (c) slika filtrirana primjenom adaptivnog filtra



(c)

Slika 7.4: Adaptivno filtriranje: (a) ulazna slika, (b) slika filtrirana korištenjem fiksne jezgre, (c) slika filtrirana primjenom adaptivnog filtra

7.2 Primjena na detekciju dima



Slika 7.5: Struktura Inteligentnog protupožarnog nadzornog sustava IPNAS

Požari otvorenog prostora predstavljaju konstantnu prijetnju ekološkim sustavima, infrastrukturi i ljudskim životima. Prema prognozama, šumski požari, uključivo i namjerno paljenje šuma u tropskim područjima, prepoloviti će do 2030. količinu šuma na svijetu. U Europi svake godine izgori i više od $10.000km^2$ različite vegetacije, a u Rusiji i Sjevernoj Americi čak $100.000km^2$. Oko 20% emisije CO_2 u atmosferu dolazi od šumskih požara [86].

Jedini efikasni način minimizacije štete koji uzrokuju požari otvorenog prostora je pravovremeno uočavanje požara u nastajanju te brza i dobra intervencija. Zbog toga se veliki napori ulažu u ranu detekciju šumskog požara. Tradicionalno, rana detekcija temelji se na ljudskim osmatračima koji tijekom požarne sezone dežuraju na osmatračkim lokacijama nastojeći što prije uočiti požar u nastajanju. Relativno



Slika 7.6: Motrilačka stanica na lokaciji Marjan i upravljačko sučelje sustava IPNAS

nova tehnologija je postavljanje daljinski upravljanih kamera na motrilačkim lokacijama i prebacivanje motrioca u operativni centar odakle on upravlja i nadzire veće područje pokriveno s više kamera, a napredni sustavi uključuju i module za automatsku detekciju požara u nastajanju.

7.2.1 Inteligentni protupožarni nadzorni sustav

Inteligentni protupožarni nadzorni sustav $IPNAS^1$ [88, 89] razvijen je na Fakultetu elektrotehnike, strojarstva i brodogradnje² Sveučilišta u Splitu uz potporu Ministarstva znanosti, obrazovanja i sporta Republike Hrvatske kroz program tehnologijskih projekata. IPNAS je integralni i inteligentni sustav za daljinski protupožarni nadzor otvorenog prostora i automatsko rano otkrivanje šumskog požara analizom slike u vidljivom dijelu spektra tijekom dana, a u bliskom infra-crvenom dijelu spektra tijekom noći. Struktura sustava IPNAS prikazana je na slici 7.5. Na slici 7.6 prika-

¹http://ipnas.fesb.hr ²http://www.fesb.hr



Slika 7.7: Požar u nastajanju detektiran sustavom IPNAS (Buzet, Istra)

zana je motrilačka postaja na lokaciji *Marjan* i upravljačko sučelje sustava. Šumski požari otkrivaju se u nastanku naprednim metodama obrade i analize slike. Inteligentni algoritmi za prepoznavanje šumskog požara automatski analiziraju sliku, tražeći vidljive znakove vatre, poput dima šumskog požara u dnevnim uvjetima i plamena u noćnim uvjetima. U slučaju sumnje na požar generira se alarmni prozor, a sumnjivi dijelovi slike se označe. Na slici 7.7 dan je primjer pravog požara u nastanku detektiranog sustavom *IPNAS*, a primjer lažnog alarma prikazan je slikom 7.8. Konačnu odluku o uzbunjivanju donosi operater pregledom detektiranih sumnjivih situacija.

7.2.2 Detekcija dima u vidljivom dijelu spektra

U dnevnom režimu rada, automatska detekcija požara temelji se na analizi video signala u vidljivom dijelu spektra i otkrivanju pojave dima. Algoritam detekcije koristi više metoda za uočavanje različitih karakteristika dima, koje se mogu podijeliti na statičke i dinamičke. Statičke metode temelje se na analizi boje, teksture i morfometrijskih karakteristika izdvojenih objekata raznim metodama i uočavanju značajki karakterističnih za dim unutar jedne slike. Rezultat analize svake slike zasebno kombinira se sa dinamičkom analizom slijeda uzastopnih slika, a konačna odluka o informiranju operatera donosi se sustavom glasanja, kod kojeg se rezultati



Slika 7.8: Lažni alarm, detektirana je prašina nastala prolaskom vozila (Buzet, Istra)

dobiveni svakom od metoda kombiniraju uz korištenje adaptivnih težinskih faktora.

Osnovni problem u točnom otkrivanju karakteristika dima predstavlja relativno niska kvaliteta ulaznog video signala zbog utjecaja svjetlosnih efekata, magle, atmosferskih čestica i drugih smetnji koje se javljaju kod kamera postavljenih na nadzornim točkama u prirodi koje su često teško dostupne. Dodatno, korištenjem okretnih kamera, sa ciljem boljeg pokrivanja nadziranog područja (kamera pokriva 360°), vremenski period između dvije uzastopne slike istog dijela teritorija ovisi o vremenu potrebnom za prolaz kroz sve nadzirane pozicije, što otežava dinamičku analizu slijeda slika.

7.2.3 Detekcija pokreta

Dinamička analiza slijeda slika temelji se na metodi detekcije pokreta. Uočavanjem dijelova slike na kojima je došlo do značajnije promjene izdvajaju se područja na kojima postoji mogućnost postojanja dima. Implementirani algoritam detekcije pokreta temelji se na metodi adaptivne pozadine i praga detekcije [87]. Ovaj model izdvaja skupine piksela slike sa detektiranom promjenom za koje vrijedi

$$b_n = \{x : |I_n(x) - B_n(x)| > T_n(x), x \in R\},$$
(7.3)

gdje je n diskretni korak detekcije (n-ta sliku u nizu), b_n nakupina piksela na kojima je detektirana promjena, $I_n(x)$ intenzitet slike u točki x, $B_n(x)$ intenzitet adaptivne pozadine, $T_n(x)$ visina adaptivnog praga, te R područje u kojem se traži pokret. Vrijednosti pozadine i praga u n + 1 diskretnom koraku računaju se prema

$$B_{n+1}(x) = \begin{cases} \alpha B_n(x) + (1-\alpha)I_n(x), & \text{na } x \text{ nema promjene} \\ B_n(x), & \text{promjena na } x \end{cases}$$
(7.4)

$$T_{n+1}(x) = \begin{cases} \alpha T_n(x) + (1-\alpha)(5|I_n(x) - B_n(x)|), & \text{na } x \text{ nema promjene} \\ T_n(x), & \text{promjena na } x \end{cases}$$
(7.5)

Za početnu pozadinu B_0 uzima se prva slika u nizu. Nedostatak opisane metode detekcije pokreta je trajno otkrivanje promjene na statičnim objektima koji se nakon ulaska u kadar na istom mjestu zadržavaju duže vrijeme (na primjer vozilo ili plovilo). Naime, prema jednadžbi 7.4, pozadina se na pikselu x prilagođava novim slikama samo u slučaju da u toj točki nije detektirana promjena. U suprotnom, pozadina u narednoj iteraciji ostaje ista, a nepomični objekt se detektira kao područje promjene. Za sustav detekcije dima, jednadžba 7.4 prilagođena je na sljedeći način:

$$B_{n+1}(x) = \begin{cases} \alpha B_n(x) + (1-\alpha)I_n(x), & \text{na } x \text{ nema promjene} \\ \alpha B_n(x)/4 + (1-\alpha/4)I_n(x), & \text{promjena na } x \end{cases}$$
(7.6)

Primjenom manjeg faktora prilagodbe u slučaju detekcije pokreta, osigurava se da objekt koji se pojavi u kadru bude detektiran u nekoliko prvih iteracija. S druge strane, sporijim učenjem pozadine u slučaju detekcije pokreta, objekti koji se duže vrijeme zadržavaju na istom mjestu u kadru se kroz nekoliko iteracije ipak usvoje kao dio pozadine. Primjenom opisanog modela detekcije pokreta osigurano je kvalitetno otkrivanje promjena na motrenoj lokaciji, uz adaptivnost sustava prema atmosferskim uvjetima i pojavi statičnih objekata u kadru.

7.2.4 Adaptivno filtriranje smetnji

Primjenom opisane metode detekcije pokreta na niz slika otvorenog prostora rezultira razmjerno velikom količinom šuma, tj. detektiranih promjena koje nisu odraz stvarnih pokreta na nadziranom području, već su posljedica pojava kao što su micanje vegetacije na vjetru ili refleksija svjetlosti na udaljenim predjelima i atmosferskim česticama. Dodatno, korištenjem okretnih kamera interval između dvije uzastopne snimke može se produžiti na više od 50 sekundi (period okretanja za 360°), što povećava razliku. Iako je količinu detektiranog šuma moguće umanjiti filtriranjem ulazne slike, ovim postupkom može se dijelom izgubiti informacijski sadržaj. S obzirom na prirodu problema i potrebu za detektiranjem dima u ranoj fazi nastanka požara na što većoj udaljenosti od kamere u složenim uvjetima (maglovito vrijeme, atmosferska prljavština, snimanje u smjeru Sunca i slično), postupak neselektivnog filtriranja značajno bi umanjio učinkovitost sustava detekcije.

Sa ciljem smanjenja šuma, uz zadržavanje bitnog informacijskog sadržaja, kao prvi korak obrade ulazne slike primjenjena je metoda adaptivnog filtriranja opisana u prvom dijelu ovog poglavlja. Ovim postupkom reducira se informacijski sadržaj slike zaglađivanjem brzih lokalnih promjena, uz zadržavanje jasnih granica među zasebnim regijama na sceni i karakteristika svih objekata.

Rezultat dinamičke analize slijeda slika sa nadzorne kamere sustava *IPNAS* postavljene na nadzornoj postaji Crni vrh u Nacionalnom parku Paklenica dan je na slikama 7.9 i 7.10. Po retcima su redom prikazane ulazna slika, rezultat dinamičke analize na nefiltriranim slikama i rezultat dinamičke analize na slikama obrađenim adaptivnim filtrom. U drugom i trećem retku su crvenom bojom označena područja sa detektiranom promjenom. Površina slike sa detektiranom promjenom izražena u broju piksela dana je u tablici 7.1. Prvi i drugi stupac redom odgovaraju rezultatu dinamičke analize na nefiltriranim slikama i slikama filtriranim adaptivnim filtrom, a treći stupac daje relativan odnos površine detektirane sa i bez primjene adaptivnog filtra. Kako na ovom slijedu slika nema stvarne promjene, sva sumnjiva područja izdvojena dinamičkom analizom predstavljaju šum, tj. smetnju koja se javlja kao posljedica atmosferskih uvjeta i relativno velikog vremenskog razmaka između dvije uzastopne slike. Smanjenje smetnji, mjereno u relativnom odnosu površine slike sa pogrešno detektiranom promjenom, ostvareno primjenom postupka adaptivnog filtriranja kreće se i do 75%.

neobrađena slika	filtrirana slika	odnos broja piksela
27476	10496	0.38201
30864	9999	0.32397
18624	7563	0.40609
27940	7216	0.25827

Tablica 7.1: Detekcije pokreta na protupožarnoj nadzornoj kameri na postaji *Crni* vrh, NP Paklenica. Prikazani je broj detektiranih piksela za nefiltrirane slike i slike filtrirane adaptivnim niskopropusnim filtrom. Zadnji stupac prikazuje relativan odnos drugog i prvog stupca. Na slikama nema stvarne promjene.

Na slikama 7.11 i 7.12 prikazan je rezultat dinamičke analize slijeda slika sa nadzorne kamere na lokaciji Marjan. Na slikama je prikazan stvarni požar u nastajanju, snimljen 26. srpnja 2006. godine na području grada Kaštela, koji je sustavom *IP*-*NAS* uspješno detektiran. Prvi redak prikazuje ulaznu sliku dobivenu sa nadzorne kamere, a pojava dima vidljiva je od druge slike u nizu. U drugom i trećem retku prikazan je rezultat dinamičke analize primijenjene na nefiltrirane slike i slike filtrirane adaptivnim filtrom, pri čemu su crvenom bojom označena sumnjiva područja sa detektiranom promjenom. Dinamičkom analizom uočeno je područje u kojem dolazi do pojave dima. U slučaju primjene na nefiltrirane slike (drugi redak), pored dima, promjena se detektira i u urbanom dijelu nadziranog područja, što se može objasniti razlikom u refleksiji svjetlosti na građevinama i ljudskom aktivnošću. Primjenom postupka adaptivnog filtriranja smetnje su reducirane, uz zadržavanje točne detekcije područja na kojem se pojavila stvarna promjena.



Slika 7.9: Dinamička analiza slijeda slika, nadzorna postaja Crni Vrh, Nacionalni park Paklenica. Po recima: ulazna slika, rezultat dinamičke analize, rezultat dinamičke analize na slikama filtriranim adaptivnim filtrom.



Slika 7.10: Nastavak sekvence sa prethodne slike. Odnos površine sa detektiranom promjenom na izvornim slikama (drugi redak) i na filtriranim slikama (treći redak) dan je u tablici 7.1



Slika 7.11: Požar u početnoj fazi, Kaštela, 26.07.2006. slijed slika sa nadzorne kamere na Marjanu. Po recima: ulazna slika, rezultat dinamičke analize, rezultat dinamičke analize na slikama filtriranim adaptivnim filtrom.



Slika 7.12: Nastavak sekvence sa prethodne slike. Dinamičkom analizom na neobrađenim slikama detektira se dim, ali i šum u urbanom području. Primjenom postupka adaptivnog filtriranja smanjuje se količina šuma uz jednaku učinkovitost u detekciji dima.

Poglavlje 8 Zaključak

Problem dekompozicije složene scene na sastavne dijelove fundamentalni je korak analize i razumijevanja vizualne informacije, koja je temeljni izvor percepcije okoline čovjeka te oblikuje naše poimanje stvarnosti i svijeta koji nas okružuje. Uočavanjem homogenih regija i jezgrovitom reprezentacijom scene efektivno se smanjuje obim ulazne informacije uz zadržavanje bitnog informacijskog sadržaja. Postupak segmentacije, kao prvi u nizu procesa koji vode do razumijevanja scene, zadaća je niske razine i temelji se na uočavanju i tumačenju jednostavnih tragova kao što su varijacije u boji, diskontinuiteti ili zajednička dinamička svojstva dijelova slike koji predstavljaju cjelovite objekte. Ovaj je proces kod živih bića upravljan kompleksnim spoznajama i iskustvom pohranjenim u višim razinama svijesti.

Segmentacija slike usko je povezana sa klasičnim problemom organiziranja skupa uzoraka u podgrupe koje zadovoljavaju određeni predikat homogenosti, a u literaturi su predložena brojna rješenja koja do perceptualno logične podjele slike na regije dolaze primjenom metoda klasteriranja na neke od atributa vizualne informacije, kao i metode koje konačnu segmentaciju generiraju kombiniranjem rezultata više različitih metoda temeljenih na istim ili različitim tragovima niske razine. Zajednička osobina većine metoda segmentacije je da se pri podjeli slike na regije malo ili uopće ne koriste spoznajama više razine, a dio autora zbog ove činjenice zastupa tezu da se učinkovitost postupka segmentacije ne može evaluirati zasebno, već kroz rezultate kompleksnog sustava računalnog vida.

Osnovni znanstveni doprinos ovog rada razvoj je nove neparametarske metode segmentacije temeljene na procjeni funkcije gustoće vjerojatnosti u domeni boja. Adaptivna metoda segmentacije slike mrežom diskretnih elemenata (Adaptive Mesh Based Image Segmentation - AMBIS) proces segmentacije dijeli na dva osnovna koraka, filtriranje slike u domeni boja i klasteriranje u prostornoj domeni. Diskretizacijom domene boja i estimiranjem funkcije gustoće ulaznih podataka korištenjem adaptivne jezgre određuju se dominantne boje i gravitirajuća područja čime se reducira voluminoznost ulazne informacije uz isticanje bitnog informacijskog sadržaja, a

preslikavanjem u prostornu domenu dobiva se inicijalna segmentacija slike. Konačna segmentacija dobiva se postprocesiranjem u prostornoj domeni, a u ovom koraku se zbog relativno male količine ulaznih podataka mogu efikasno primijeniti razne metode klasteriranja.

Motivacija za razvoj ove metode potekla je od potrebe za dobivanjem kvalitetnih segmentacija u sustavu video nadzora koji radi u stvarnom vremenu. Uvjet izvršavanja u stvarnom vremenu nužno ograničava složenost metode čime je limitirana mogućnost implementacije postupaka segmentiranja koji do kvalitetnog rješenja dolaze vremenski zahtjevnim postupcima. Drugi temeljni preduvjet bila je mogućnost integracije sa drugim postupcima analize slike, u prvom redu sa rezultatima dinamičke analize slijeda slika. Pri tom, zbog složenih i promjenjivih uvjeta rada sustava video nadzora, metoda segmentacije ne može polaziti od bilo kakvih implicitnih pretpostavki o broju i karakteristikama zasebnih regija na slici ili strukturi prostora.

Ideja diskretizacije domene boja i procjene gustoće jezgrom nastala je promatranjem metoda klasteriranja temeljenih na analizi funkcije gustoće. Ove metode polaze od pretpostavke da se mapiranjem uzoraka u višedimenzionalni vektorski prostor i otkrivanjem područja veće gustoće mogu uočiti značajne karakteristike podataka. Efikasnost postupka pronalaženja žarišta funkcije gustoće u odnosu na metode koje do lokalnih maksimuma dolaze analitički povećana je diskretizacijom domene, a razdvajanjem obrade u domeni boja i prostornoj domeni smanjena je dimenzionalnost prostora čime je dalje smanjena memorijska i vremenska složenost.

Drugi temeljni zahtjev stabilnosti i robusnosti metode segmentacije u složenim uvjetima rada nadzornog video sustava zadovoljen je implementiranjem interne prilagodljivosti parametara metode ulaznim podacima. Implementacijom jezgre adaptivne pojasne propusnosti estimirana funkcija gustoće domene boja bolje odražava karakteristike inherentne funkcije distribucije podataka, a adaptivnost metode na ulazne podatke dodatno je povećana relativnom razinom otkrivanja šuma. Ovako realizirana metoda segmentacije stabilnija je u promjenjivim uvjetima rada nadzornog sustava, uz sposobnost otkrivanja detalja različite skale.

Razvijena metoda ispitana je korištenjem javno dostupne baze testnih slika, od kojih je za svaku dostupno pet do sedam ručno napravljenih segmentacija, a kvaliteta računalno generiranih segmentacija ocijenjena je jasnom numeričkom mjerom. Rezultati su evaluirani temeljem više kriterija koji uključuju maksimalnu kvalitetu, prosječnu kvalitetu, stabilnost s obzirom na upravljačke parametre i stabilnost s obzirom na različite slike, te efikasnost obrade. Komparativna evaluacija provedena je usporedbom ostvarenih rezultata s rezultatima dvije postojeće neparametarske metode segmentacije. Metoda srednjeg pomaka, široko prihvaćena i jedna od temeljnih metoda računalnog vida, također se temelji na procjeni funkcije gustoće vjerojatnosti, a do rješenja dolazi analitički, određivanjem gradijenta estimirane gustoće. Druga korištena metoda je tehnika efikasne segmentacije slike temeljena na grafu, koja, pored kvalitete dobivenih rezultata, kao temeljni kriterij upotrebljivosti algoritma segmentacije postavlja i efikasnost obrade. Ove dvije metode predstavnici su različitih pristupa problemu segmentacije slike, a za obje metode dostupne su računalne implementacije pripremljene od strane samih autora, čime je osigurana objektivnost evaluacije s obzirom na kvalitetu implementacije svake od ispitanih metoda. Prosječno najviša kvaliteta segmentacija u provedenim eksperimentima dobivena je metodom srednjeg pomaka. Kvaliteta segmentacija dobivenih AMBIS metodom nešto je niža u usporedbi s rezultatima dobivenim metodom srednjeg pomaka, uz veću stabilnost s obzirom na izbor upravljačkih parametara. Najlošiji rezultati dobiveni su metodom efikasne segmentacije slike temeljene na grafu. Sa stanovišta efikasnosti, AMBIS metoda pokazuje najbolje rezultate, sa prosječno dest puta kraćim vremenom obrade u odnosu na metodu srednjeg pomaka. Analizom rezultata utvrđen je povoljan odnos kvalitete i efikasnosti, sa mogućnošću primjene predložene metode u sustavima računalnog vida koji rade u stvarnom vremenu.

Teoretskom i eksperimentalnom analizom pojedinih faza algoritma segmentacije izdvojeni su koraci najveće računalne složenosti. Temeljem provedene analize, predložena metoda segmentacije implementirana je u asinkronom paralelnom modelu računanja. Ovaj model opisuje moderne računalne arhitekture sa višestrukim paralelnim podsustavima obrade. Paralelnom implementacijom *AMBIS* metode segmentacije slike dodatno je povećana efikasnost obrade uz zadržavanje jednake razine kvalitete dobivenih segmentacija.

Brza metoda segmentacije procjenom gustoće domene boja implementirana je u Inteligentnom protupožarnom nadzornom sustavu IPNAS. IPNAS je integralni sustav protupožarnog nadzora otvorenog prostora, čiji je sastavni dio modul za automatsko otkrivanje požara otvorenog prostora u nastajanju analizom slike video kamere. Ključni uvjeti za primjenu metode segmentacije u ovakvom sustavu su efikasnost i robusnost u složenim uvjetima obrade slike relativno niske kvalitete dobivene nadzorom velikih otvorenih prostora. AMBIS metoda segmentacije integrirana je u postupak adaptivnog filtriranja, primijenjenog kao prvi korak analize slike sa ciljem smanjenja smetnji i uklanjanja artefakta koji nastaju kao posljedica atmosferskih uvjeta. Implementacija postupka adaptivnog filtriranja utjecala je na kvalitetu sustava automatske detekcije požara smanjenjem broja pogrešno detektiranih sumnjivih područja.

Analizom rezultata i efikasnosti predložene metode u kontroliranim eksperimentalnim uvjetima, kao i implementacijom u sustavu video nadzora u stvarnom vremenu, utvrđena je kvaliteta, robusnost i učinkovitost koja omogućava primjenu predložene metode u složenim sustavima računalnog vida. Temeljni znanstveni doprinosi ovog rada su sljedeći:

• Razvoj inovativne metode segmentacije slike temeljem procjene gustoće diskretizacijom domene boja

Razvijena metoda adaptivna je s obzirom na ulaznu sliku, a efikasnost obrade čini je pogodnom za primjenu u problemima računalnog vida kod kojih se rješenje traži u stvarnom vremenu. Mogućnost integracija sa drugim postupcima obrade slike i upravljanje algoritmom segmentacije procesima više razine ostvarena je malim brojem intuitivno jasnih upravljačkih parametara. Funkcionalnost i efikasnost razvijene metode ispitana je temeljem jasne numeričke mjere kvalitete, korištenjem javno dostupne baze slike *Berkeley Segmentation Dataset*. Kvaliteta segmentacija generiranih *AMBIS* metodom usporediva je sa kvalitetom segmentacija dobivenih postojećim metodama, uz dobru stabilnost s obzirom na ulazne parametre algoritma. Istovremeno, efikasnost predložene metode implementirane slijednim algoritmom je 5 do 50 puta veća u odnosu na *mean shift* metodu, te do dvostruko bolja u odnosu na efikasnu metodu segmentacije temeljenu na grafu.

- Implementacija metode segmentacije u asinkronoj paralelnoj paradigmi Prilagodba metode segmentacije modelu paralelnog računala je osnova za razvoj efikasnih računalnih algoritama temeljenih na predloženoj metodi, a dizajniranih za primjenu na modernom računalnom sklopovlju sa višestrukim linijama izvršavanja. Efikasnost AMBIS metode segmentacije slike implementirane u asinkronom paralelnom modelu računanja je do 20% veća u odnosu na slijedni algoritam segmentacije. Ova analiza odnosi se na ukupno vrijeme izvršavanja algoritma što uključuje i ulazno-izlazne operacije, dok se povećanje efikasnosti samog postupka segmentacije kreće i do 30%.
- Metoda adaptivnog filtriranja i primjena u sustavu za rano otkrivanje požara uočavanjem dima u vidljivom dijelu spektra
 Razvijena metoda segmentacije korištena je u konstrukciji adaptivnog filtra.
 Primjenom adaptivnog filtriranja smanjuje se obim vizualne informacije ublažavanjem lokalnih varijacija boje, uz istovremeno isticanje globalnih značajki slike naglašavanjem granica značajnih objekata. Metoda adaptivnog filtriranja koristi se u sustavu za rano otkrivanje šumskih požara, a omogućava korekciju smetnji koje nastaju kao posljedica rada kamera u složenim uvjetima, uz zadržavanje korisnog informacijskog sadržaja slike. Sustav automatske detekcije požara radi u stvarnom vremenu, a implementiran je na više lokacija u Republici Hrvatskoj.

Dodatak A

Segmentacija slike metodom srednjeg pomaka

Segmentacija slike metodom srednjeg pomaka [2, 3, 4] široko je prihvaćena u brojnim sustavima računalnog vida. Ova tehnika bazira se na analizi prostora značajki. Tipičan primjer prikazan je na slici A.1, gdje su prikazani (a) ulazna slika i (b) pikseli ulazne slike mapirani u $L^*u^*v^*$ prostor boja¹. Analizom prostora boja mogu se odrediti maksimumi funkcije gustoće svojstvene točkama slike koji odgovaraju dominantnim bojama. Područja manje gustoće čine granicu među dominantnim bojama i definiraju područja konvergencije koja predstavljaju zasebne objekte na slici. Postupak segmentacije sastoji se od dva koraka: (1) filtriranje ulaznih podataka metodom srednjeg pomaka i (2) klasteriranje filtriranih podataka. U procesu filtriranja analizira se funkcija gustoće inherentna točkama slike u nekom prostoru značajki i određuju maksimumi estimirane funkcije gustoće. Nakon filtriranja, svaki ulazni podatak (piksel slike) pridružen je pripadajućem maksimumu. U drugom koraku, grupiraju se maksimumi male međusobne udaljenosti. Ova metoda implementirana je u javno dostupnom sustavu EDISON [9]. Implementacija algoritma srednjeg pomaka u sustavu EDISON korištena je u eksperimentima provedenim u ovom radu.

A.1 Estimacija gustoće u prostoru značajki

Neka je $D = \{x_1, x_2, ..., x_N\}$ skup N ulaznih podataka u d-dimenzionalnom prostoru \mathbb{R}^d . Funkciju gustoće vjerojatnosti možemo estimirati korištenjem multivarijabilne jezgre² K(x) i simetrične pozitivno definitne matrice pojasnih širina³ **H**, tehnikom Parzenovog prozora [40]:

 $^{^1 {\}rm slika}$ je preuzeta iz izvornog rada[2]

 $^{^{2}}$ multivariate kernel

³ bandwidth matrix



Slika A.1: Analiza slike u $L^*u^*v^*$ prostoru boja. Slika je preuzeta iz izvornog rada [2]

$$f^{D}(x) = \frac{1}{N} \sum_{i=1}^{N} K_{\mathbf{H}}(x - x_{i})$$
(A.1)

gdje je

$$K_{\mathbf{H}}(x) = |\mathbf{H}|^{-\frac{1}{2}} K(\mathbf{H}^{-\frac{1}{2}}x)$$
 (A.2)

d-varijabilna jezgra K(x) je omeđena funkcija koja mora zadovoljiti sljedeće uvjete:

$$\int_{\mathbb{R}^d} K(x)dx = 1 \qquad \lim_{\|x\| \to \infty} \|x\|^d K(x) = 0$$
$$\int_{\mathbb{R}^d} xK(x)dx = 0 \qquad \int_{\mathbb{R}^d} xx^T K(x)dx = c_K \mathbf{I} \qquad (A.3)$$

gdje je c_K konstanta. U praksi se za odabir matrice pojasnih širina najčešće koristi dijagonalna matrica $\mathbf{H} = \mathbf{diag}[h_1^2, ..., h_d^2]$, ili matrica identiteta $\mathbf{H} = h^2 \mathbf{I}$. U posljednjem slučaju, dovoljno je definirati samo pojasnu propusnost h > 0, uz uvjet Euklidske metrike prostora značajki [2]. Radijalno simetrična jezgra dana je sa:

$$K(x) = c_{k,d}k(||x||^2)$$
(A.4)

Funkciju k(x) nazivamo profil jezgre K, za $x \ge 0$. Normalizacijska konstanta $c_{k,d}$ je strogo pozitivna i osigurava zadovoljenje uvjeta danih sa (A.3). Korištenjem samo jednog parametra pojasne širine, estimirana funkcija gustoće dana jednadžbom (A.5) prelazi u

$$f_{h,K}^D(x) = \frac{1}{Nh^d} \sum_{i=1}^N K\left(\frac{x-x_i}{h}\right)$$
(A.5)

$$= \frac{c_{k,d}}{Nh^d} \sum_{i=1}^N k\left(\left\|\frac{x-x_i}{h}\right\|^2\right)$$
(A.6)

U praksi se najčešće korištene *Epanechnikova* i *normalna* jezgra. Epanechnikova jezgra dana je profilom

$$k_E(x) = \begin{cases} 1-x & 0 \le x \le 1\\ 0 & x > 1 \end{cases}$$
(A.7)

koji rezultira radijalno simetričnom jezgrom

$$K_E(x) = \begin{cases} \frac{1}{2}c_d^{-1}(d+2)(1-\|x\|^2) & \|x\| \le 1\\ 0 & \|x\| > 1 \end{cases}$$
(A.8)

gdje je c_d volumen jedinične d-dimenzionalne sfere. Korištenjem profila

$$k_G(x) = e^{-\frac{1}{2}x}$$
 (A.9)

dobija se normalna jezgra

$$K_G(x) = (2\pi)^{-\frac{d}{2}} e^{-\frac{1}{2}||x||^2}$$
(A.10)

koja je u pravilu simetrično ograničena zbog definiranja jezgre kao simetrične omeđene funkcije. Iako se dvije navedene jezgre najčešće susreću u većini aplikacija, koristiti se može bilo koja funkcija koja zadovoljava uvjete dane sa (A.3) pa analiza provedena u ostatku teksta vrijedi za proizvoljnu jezgru.

A.2 Estimacija gradijenta gustoće

Prvi korak u analizi prostora značajki je određivanje maksimuma funkcije gustoće u kojima vrijedi $\nabla f^D(x) = 0$. Estimirani gradijent funkcije gustoće definiramo kao gradijent estimirane funkcije gustoće:

$$\nabla f_{h,K}^D(x) = \frac{2c_{k,d}}{Nh^{d+2}} \sum_{i=1}^N (x - x_i) k' \left(\left\| \frac{x - x_i}{h} \right\|^2 \right)$$
 (A.11)

Ako pretpostavimo da derivacija profila k(x) postoji za sve $x \in [0, \infty)$, osim za konačan skup točaka, možemo definirati profil g(x) = -k'(x) i jezgru

$$G(x) = c_{g,d}g(||x||^2), \qquad (A.12)$$

gdje je $c_{g,d}$ pripadajuća normalizacijska konstanta. Uvrštavanjem g(x) u jednadžbu (A.11) dobivamo:

$$\nabla f_{h,K}^{D}(x) = \frac{2c_{k,d}}{Nh^{d+2}} \sum_{i=1}^{N} (x_{i} - x)g\left(\left\|\frac{x - x_{i}}{h}\right\|^{2}\right)$$
(A.13)
$$= \frac{2c_{k,d}}{Nh^{d+2}} \left[\sum_{i=1}^{N} g\left(\left\|\frac{x - x_{i}}{h}\right\|\right)^{2}\right] \left[\frac{\sum_{i=1}^{N} x_{i}g\left(\left\|\frac{x - x_{i}}{h}\right\|^{2}\right)}{\sum_{i=1}^{N} g\left(\left\|\frac{x - x_{i}}{h}\right\|^{2}\right)} - x\right]$$

Prvi član gornjeg izraza proporcionalan je estimaciji gustoće korištenjem jezgre G:

$$f_{h,G}^{D} = \frac{c_{g,d}}{nh^{d}} \sum_{i=1}^{N} g\left(\left\| \frac{x - x_{i}}{h} \right\|^{2} \right)$$
(A.14)

Drugi član je *srednji pomak* i predstavlja razliku ponderirane srednje vrijednosti, čiji su težinski faktori dani jezgrom G, i centralne točke jezgre x:

$$\mathbf{m}_{h,G}(x) = \frac{\sum_{i=1}^{N} x_i g\left(\left\| \frac{x - x_i}{h} \right\|^2 \right)}{\sum_{i=1}^{N} g\left(\left\| \frac{x - x_i}{h} \right\|^2 \right)} - x$$
(A.15)

Uvrštavanjem jednadžbi (A.14) i (A.15) u (A.13) dobijamo

$$\nabla f_{h,K}^D = f_{h,G}^D(x) \frac{2c_{k,d}}{h^2 c_{g,d}} \mathbf{m}_{h,G}(x), \qquad (A.16)$$

iz čega slijedi

$$\mathbf{m}_{h,G}(x) = \frac{1}{2}h^2 c \frac{\nabla f_{h,K}^D(x)}{f_{h,G}^D(x)}$$
(A.17)

A.3 Klasteriranje metodom srednjeg pomaka

Vektor srednjeg pomaka, definiran jednadžbom (A.17), proporcionalan je u točki x normaliziranom estimiranom gradijentu gustoće izračunate jezgrom K, a pokazuje u smjeru maksimalnog povećanja gustoće. Ovaj smjer određuje područje u kojem se nalazi veći broj točaka ulazne slike. Iterativnim proračunom vektora srednjeg pomaka moguće je odrediti maksimume gustoće bez računanja same estimirane funkcije gustoće na sljedeći način:

- 1. U točki x izračunaj vektor srednjeg pomaka $\mathbf{m}_{h,G}(x)$
- 2. Translatiraj jezgru G(x) za $\mathbf{m}_{h,G}(x)$
- 3. Ponovi korake 1-2 do postizanja konvergencije

Opisana procedura definira postupak filtriranja ulaznih podataka, koji svakom ulaznom podatku x_i pridružuje pripadajući maksimum x'_i . Točke x_i, x_j za koje vrijedi $x'_i = x'_j$ nalaze u istoj grupi u konačnom rezultatu klasteriranja.

U drugom koraku algoritma, klasteriraju se filtrirani podaci $\{x'_1, ..., x'_N\}$. U izvornom algoritmu segmentacije slike metodom srednjeg pomaka, opisanom u [2],

klasteriranje je definirano kao jednostavno grupiranje maksimuma čija je međusobna udaljenost manja od širine jezge.

A.4 EDISON: Segmentacija slike

Algoritam segmentacije slike predložen u [2] i implementiran u sustavu *EDISON* [9] primjenjuje metodu srednjeg pomaka u 5-dimenzionalnom prostoru značajki za klasteriranja piksela slike u zasebne regije. Algoritam je implementiran u približno u združenoj domeni boja i prostornoj domeni. Kao prostor boja koristi se $L^*u^*v^*$ zbog svoje približne uniformnosti.

Algoritam segmentacije upravljan je sa dva parametra koji definiraju pojasnu propusnost u prostornim koordinatama slike (h_s) i prostoru boja (h_r) . U prvom koraku algoritma, slika se filtrira metodom srednjeg pomaka u 5D prostoru značajki, čime se individualna boja svakog piksela zamjeni 3D komponentom boje pripadajućeg maksimuma u 5D prostoru značajki. U idućem koraku, rekurzivno se povezuju susjedne regije na slici čiji su pripadajući maksimumi udaljeni za manje od $h_r/2$ u $L^*u^*v^*$ prostoru boja. Proces filtriranja slike optimiran je na način da se pikseli koji se nalaze u blizini trajektorije vektora srednjeg pomaka drugog, već obrađenog piksela automatski pridružuju istom maksimumu. Prema autorima, ovim postupkom proces filtriranja je ubrzan za oko 5 puta, bez vidljivih gubitaka u kvaliteti.

Sustav *EDISON* kao opciju pri generiranju segmentacije slike nudi korištenje informacije dobivene detekcijom rubova. Uključenjem ove opcije, konačan rezultat dobiva se kombiniranjem rezultata segmentacije metodom srednjeg pomaka i detektiranih rubova na slici. Podjele slike na homogene regije i ekstrakcije rubova su u svojoj prirodi komplementarni postupci, ali se zbog različitog pristupa problemu konačni rezultati mogu značajno razlikovati, a kombiniranje rezultata može povećati kvalitetu dobivene segmentacije. Ova opcija nije korištena u eksperimentima provedenim u ovoj disertaciji.

Detaljan opis sustava *EDISON*, kao i izvorni kod samog programa, dostupni su na adresi http://www.caip.rutgers.edu/riul/research/code.html

Dodatak B

Efikasna segmentacija slike particioniranjem grafa

Algoritam segmentacije slike predložen u [12] temelji se na odabiru rubova grafa, gdje svaki čvor odgovara jednom pikselu slike, a rubovi grafa predstavljaju veze između susjednih piksela. Segmentacijski kriterij odabira rubova adaptivno se prilagođava prema stupnju varijabilnosti u okolini piksela slike. Dokaz o postojanju granice među regijama na slici temelji se na usporedbi dvije vrijednosti: varijacije preko granice i varijacije unutar piksela svake od regija. Granica među regijama se smatra perceptualno značajnom ako su varijacije preko granice velike u odnosu na varijacije unutar bar jedne od regija.

B.1 Particioniranje grafa

Neka je G = (V, E) neusmjereni graf, gdje svaki čvor $v_i \in V$ predstavlja jedan ulazni podatak, a rub $(v_i, v_j) \in E$ povezuje par susjednih čvorova. Svaki rub $(v_i, v_j) \in E$ ima pripadajuću težinu $w(v_i, v_j)$. Težina $w(v_i, v_j)$ predstavlja nenegativnu mjeru različitosti između susjednih čvorova v_i i v_j .

Segmentacija S je particija skupa V u komponente takve da svaka komponenta $C \in S$ odgovara povezanoj komponenti u grafu G' = (V, E'), gdje je $E' \subseteq E$. Intuitivno, dobra segmentacija je ona kod koje je težina rubova među čvorovima iste komponente relativno mala u odnosu na težinu rubova među čvorovima različitih komponenti.

B.2 Kriterij postojanja granice

Kriterij postojanja granice D između dviju komponenti segmentacije temeljen je na mjerenju težina rubova koji povezuju čvorove uzduž granice i relativnom odnosu prema težinama rubova unutar svake od komponenti. Unutarnju razliku komponente $C \subseteq V$ definiramo kao najveću težinu minimalno razapetog stabla¹ MST(C, E) komponente C:

$$Int(C) = \max_{e \in MST(C,E)} w(e)$$
(B.1)

Razliku između komponenti $C_1, C_2 \subseteq V$ definiramo kao minimalnu težinu ruba koji povezuje komponente C_1 i C_2 :

$$Dif(C_1, C_2) = \min_{v_i \in C_1, v_j \in C_2, (v_i, v_j) \in E} w((v_i, v_j)),$$
(B.2)

pri čemu se, ukoliko ne postoji rub koji povezuje komponente C_1 i C_2 , uzima $\text{Dif}(C_1, C_2) = \infty$. Kriterij postojanja granice definiramo kao:

$$D(C_1, C_2) = \begin{cases} 1 & (true) & \text{ako vrijedi} \quad \text{Dif}(C_1, C_2) > \text{MInt}(C_1, C_2) \\ 0 & (false) & \text{inače} \end{cases}, \quad (B.3)$$

gdje je MInt adaptivna funkcija praga, a dana je sa:

$$MInt(C_1, C_2) = \min(Int(C_1) + \tau(C_1), Int(C_2) + \tau(C_2))$$
(B.4)

Funkcija $\tau(C)$ kontrolira stupanj za koji razlika između komponenti mora biti veća u odnosu na interne varijacije da bi se smatrala dokazom o postojanju ruba, a temeljena je na veličini komponente C:

$$\tau(C) = \frac{\kappa}{|C|},\tag{B.5}$$

gdje je |C| veličina (broj piksela) komponente C, a κ konstanta. Funkcija $\tau(C)$ osigurava adaptivnost praga s obzirom na veličinu komponente, pri čemu se za manje komponente traži jači dokaz postojanja granice. Sama mjera Int(C) za male komponente ne odražava dobro lokalnu varijabilnost podataka, a u ekstremnom slučaju |C| = 1 vrijedi Int(C) = 0, što bi rezultiralo segmentacijom u kojo je svaki ulazni podatak zasebna klasa. Parametar κ određuje skalu opservacije, gdje veći κ preferira veće komponente. S druge strane, ovaj parametar ne određuje minimalnu veličinu komponente, a manje komponente su dozvoljene sve dok postoji dovoljno jak dokaz o postojanju granice.

¹minimum spanning tree

B.3 Algoritam segmentacije slike

Algoritam segmentacije slike opisan u [12] definira neusmjereni graf G = (V, E), kod kojeg je svaki piksel ulazne slike p_i predstavljen vrhom $v_i \in V$. Skup rubova Ekonstruiran je povezivanjem svakog piksela sa 8 susjednih piksela koji ga okružuju. Algoritam je izvorno zamišljen za segmentaciju slike sivih razina, u kojem slučaju se funkcija težine ruba definira kao apsolutna razlika intenziteta piksela koje promatrani rub povezuje:

$$w((v_i, v_j)) = |I(p_i) - I(p_j)|,$$
(B.6)

gdje $I(p_i)$ predstavlja intenzitet (svjetlinu) piksela p_i . Kod segmentacije slike u boji, moguća su dva pristupa. U prvom slučaju, algoritam se pokreće tri puta, zasebno za svaku komponentu boje, a konačna segmentacija dobija se kombiniranjem rezultata, na način da se susjedni pikseli postavljaju u istu komponentu samo ako su u istoj komponenti u sva tri slučaja. U drugom slučaju algoritam segmentacije se pokreće samo jednom, uz definiranje funkcije težine ruba kao udaljenosti među pikselima u nekom prostoru boja. Prema autorima, bolji rezultati postižu se pokretanjem algoritma zasebno za svaku komponentu boje i kombiniranjem rezultata.

Detaljan opis implementacije opisanog algoritma, kao i izvorni kod programa, dostupni su na adresi http://people.cs.uchicago.edu/~pff/segment/

Bibliografija

- P. Meer "Robust techniques for computer vision", Emerging Topics in Computer Vision, G. Medioni and S. B. Kang (Eds.), Prentice Hall, Upper Saddle River, New Jersey 07458, pp. 107-190, 2004.
- [2] Dorin Comaniciu, Peter Meer, "Mean Shift: A Robust Approach Toward Feature Space Analysis", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 24, No. 5, pp. 603-619, 2002.
- [3] Dorin Comaniciu, Peter Meer, "Mean Shift Analysis and Applications", Proceedings of the International Conference on Computer Vision, Vol. 2, pp. 1197-1203, 1999.
- [4] Dorin Comaniciu, Peter Meer, "Robust Analysis of Feature Spaces: Color Image Segmentation", IEEE Conf. on Comp. Vis. and Pattern Recognition, pp. 750-755, Puerto Rico 1997.
- [5] Dorin Comaniciu, V. Ramesh, Peter Meer, "The Variable Bandwidth Mean Shift and Data-Driven Scale Selection", Proceedings. Eighth IEEE International Conference on Computer Vision, Vancouver, BC, Canada, Vol. 1, pp. 438-445, July 2001.
- [6] Dorin Comaniciu, "An Algorithm for Data-Driven Bandwidth Selection", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 25, No. 2, pp. 281 - 2885, 2003.
- [7] Ian S. Abramson, "On Bandwidth Variation in Kernel Estimates-A Square Root Law", Annals of Statistics, Vol. 10, No. 4, pp. 1217-1223, 1982.
- [8] P. Hall, T. C. Hu, J. S. Marron, "Improved Variable Window Kernel Estimates of Probability Densities", Annals of Statistics, Vol. 23, No. 1, pp. 1-10, 1995.
- [9] C. M. Christoudias, B. Georgescu, P. Meer, "Synergism in low level vision", Proceedings. 16th International Conference on Pattern Recognition, Vol. 4, pp. 150-155, 2002.

- [10] Jianbo Shi and Jitendra Malik, "Normalized Cuts and Image Segmentation", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 22, No. 8, pp. 888-905, 2000.
- [11] Ivančica Mirošević, "Spektralno particioniranje grafa i primjena na ekstrakciju znanja", Magistarski rad, Zagreb 2005.
- [12] Pedro F. Felzenszwalb and Daniel P. Huttenlocher, "Efficient Graph-Based Image Segmentation", International Journal of Computer Vision, Vol. 59, No. 2, pp. 167-181, September 2004.
- [13] R. Urquhart, "Graph Theoretical Clustering Based on Limited Neighborhood Sets", Pattern Recognition, Vol. 15, No. 3, pp. 173-187, 1982.
- [14] C. Zahn, "Graph-Theoretical Methods for Detecting and Describing Gestalt Clusters", IEEE Transactions on Computers, Vol. C20, No. 1, pp. 68-86, Jan. 1971.
- [15] K. Fukunaga, L. Hostetler, "The estimation of the gradient of a density function, with applications in pattern recognition", IEEE Transactions on Information Theory, Vol. 21, No. 1, pp. 32-40, January 1975.
- [16] Yizong Cheng, "Mean Shift, Mode Seeking, and Clustering", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 17, No. 8, pp. 790-799, August 1995.
- [17] Dorin I. Comaniciu, "Nonparametric Robust Methods for Computer Vision", The State University of New Jersey, New Brunswick, New Jersey, January 2000.
- [18] Alexander Hinneburg, Daniel A. Keim, A General Approach to Clustering in Large Databases with Noise, Knowledge and Information Systems, Vol. 5, No. 4, pp. 387-415, 2003.
- [19] Alexander Hinneburg, Daniel A. Keim, An Efficient Approach to Clustering in Large Multimedia Databases with Noise, In Proceedings of the Fourth International Conference on Knowledge Discovery and Data Mining, pp. 58-65, Menlo Park, California, 1998.
- [20] Wei-keng Liao, Ying Liu, Alok Choudhary, "A Grid-based Clustering Algorithm using Adaptive Mesh Refinement", In Proceedings of the 7th Workshop on Mining Scientific and Engineering Datasets, Lake Buena Vista, Florida, April 2004.
- [21] N. H. Park and W. S. Lee, "Statistical grid-based clustering over data streams", SIGMOD Record, Vol. 33, No. 1, pp. 32-37, 2004

- [22] G. Sheikholeslami, S. Chatterjee, A. Zhang, "WaveCluster: a wavelet-based clustering approach for spatial data in very large databases", The International Journal on Very Large Data Bases, Vol. 8, No. 3-4, pp. 289-304, 2000.
- [23] R. Agrawal, J. Gehrke, D. Gunopulos, P. Raghavan "Automatic Subspace Clustering of High Dimensional Data for Data Mining Applications", In Proceedings of the 1998 ACM SIGMOD international conference on Management of data, Seattle, Washington, pp. 94 - 105, 1998.
- [24] Z. Yu, H. S. Wong, "GCA: A real-time grid-based clustering algorithm for large data set", In Proceedings of the 2006. International Conference on Pattern Recognition, Hong Kong, China, pp. 740-743, August 2006.
- [25] Alexander Hinneburg, Daniel A. Keim, Optimal Grid-Clustering: Towards Breaking the Curse of Dimensionality in High-Dimensional Clustering, The Very Large Databases Journal, pp. 506-517, 1999.
- [26] B. A. Turlach, "Bandwidth selection in kernel density estimation: A review", Discussion Paper 9317, Institut de Statistique, Voie du Roman Pays 34, B-1348 Louvain-la-Neuve, 1993.
- [27] M. P. Wand, M. C. Jones, "Kernel Smoothing", Chapman & Hall, London, 1995.
- [28] Clive R. Loader "Bandwidth selection: classical or plug-in?", The Annals of Statistics, Vol. 27, No. 2, pp. 415-438, 1999.
- [29] V. Chandrakant Raykar and R. Duraiswami, "Fast optimal bandwidth selection for kernel density estimation", Online Proceedings of the 2006 Siam Conference on Data Mining
- [30] V. Chandrakant Raykar and R. Duraiswami, "Very fast optimal bandwidth selection for univariate kernel density estimation", Technical Report, Department of Computer Science and Institute for Advanced Computer Studies, University of Maryland, January 2006.
- [31] R.P.W. Duin, "On the Choice of Smoothing Parameters for Parzen Estimators of Probability Density Functions", IEEE Transactions on Computers, Vol. C-25, No. 11, pp. 1175-1179, 1976.
- [32] T. Gevers, H. Stokman, "Robust Histogram Construction from Color Invariants", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 26, No. 1, pp. 113-117, January 2004.
- [33] S. Russell, P. Norvig "Artificial Intelligence: A Modern Approach", Prentice Hall, Upper Saddle River, New Jersey 07458, 1995.

- [34] L. Lucchese, S.K. Mitra, "Color Image Segmentation: A State-of-the-Art Survey", Image Processing, Vision, and Pattern Recognition, Proc. of the Indian National Science Academy (INSA-A), New Delhi, India, Vol. 67 A, No. 2, pp. 207-221, Mar. 2001.
- [35] A. K. Jain, "Fundamentals of Digital Image Processing", Prentice-Hall, Englewood Cliffs, New Jersey, 1989.
- [36] John C. Russ, "Image Processing Handbook", CRC Press, Boca Raton, Florida, 1995.
- [37] T. Young "On the Theory of Light and Colours", Philosopical Transactions of the Royal Society of London, Vol. 92, 1802.
- [38] R. C. Gonzales and R. C. Woods, "Digital Image Processing", Addison-Wesley, Reading, Massachusetts, 1992.
- [39] Quan-Tuan Luong, "Color in Computer Vision, Handbook of Pattern Recognition and Computer Vision, C. H. Chen, L. F. Pau, P. S. P. Wang (Eds.) pp. 311-368, World Scientific Publishing Co., River Edge, New York, 1993.
- [40] K. Fukunaga, "Statistical Pattern Recognition", Handbook of Pattern Recognition and Computer Vision, C. H. Chen, L. F. Pau, P. S. P. Wang (Eds.) pp. 33-60, World Scientific Publishing Co., River Edge, New York, 1993.
- [41] R. M. Haralick and L. G. Shapiro, "Image Segmentation Techniques", Computer Vision, Graphics, and Image Processing, Vol. 29, No. 1, pp. 100-132, Jan. 1985.
- [42] J. McQueen "Some methods for classification and analysis of multivariate observation", Proceedings of the Fifth Berkeley Symposium on Math. Stat. Prob., University of California Press, Berkeley, Los Angeles, pp. 281-297, 1967.
- [43] L. Shafarenko and H. Petrou, J. Kittler, "Histogram-based segmentation in a perceptually uniform color space", IEEE Transactions on Image Processing, Vol. 7, No. 9, pp. 1354-1358, Sep. 1998.
- [44] D. W. Scott, S. R. Sain, "Multi-Dimensional Density Estimation", Data Mining and Computational Statistics, Vol. 23, 2004)
- [45] David W. Scott, "Averaged Shifted Histograms: Effective Nonparametric Density Estimators in Several Dimensions", The Annals of Statistics, Vol. 13, No. 3, pp. 1024-1040, 1985
- [46] M. Celenk and M. Uijt de Haag, "Optimal thresholding for color images", Proc. of the SPIE, Nonlinear Image Processing IX, San Hose, California, pp. 250-259, Jan. 1998.
- [47] A. K. Jain, M. N. Murty, A. J. Flynn, "Data Clustering: A Review", ACM Computing Surveys, Vol. 31, No. 3, pp. 264-323, September 1999.
- [48] Rui Xu, "Survey of Clustering Algorithms", IEEE Transactions on Neural Networks, Vol. 16, No. 3, May 2005
- [49] D. Hand, H. Mannila, P. Smyth, "Principles of Data Mining", MIT Press, Cambridge, Massachusetts, 2001.
- [50] S. Mitra and T. Acharya, "Data Mining: Multimedia, Soft Computing, and Bioinformatics", John Wiley & Sons, Inc., Hoboken, New Jersey, 2003.
- [51] Hui Chung Law "Clustering, Dimensionalty Reduction and Side Information", Ph. D. dissertation, Michigan State University, Department of Computer Science & Engineering, 2006.
- [52] J. Vesanto and E. Alhoniemi, "Clustering of the Self-Organizing Map", IEEE Transactions on Neural Networks, special issue on data mining, Vol. 11, No. 3, 2000.
- [53] G. Bartfai, "Hierarchical Clustering with ART Neural Networks", Proceedings of IEEE World Conference on Computational Intelligence, Orlando, Florida, 1994.
- [54] D. B. Fogel, "Evolutionary Computation: toward a new philosophy of machine intelligence", IEEE Press, Piscataway, New York, 1995.
- [55] A. Tremeau and N. Borel, "A Region Growing and Merging Algorithm to Color Segmentation", Pattern Recognition Vol. 30, No. 7, pp. 1191-1203, 1997.
- [56] Yiu-Minh Cheung, "K*-Means: A new generalized k-means clustering algorithm", Pattern Recognition Letters, Vol. 24., No. 15, pp. 2883-2893, November 2003.
- [57] C. Elkan, "Using the Triangle Inequality to Accelerate k-Means", In Proceedings of the Twentieth International Conference on Machine Learning, pp. 147-153, 2003.
- [58] S. Ray and R. H. Turi, "Determination of Number of Clusters in K-Means Clustering and Application in Colour Image Segmentation", in Proceedings of the 4th International Conference on Advances in Pattern Recognition and Digital Techniques, pp. 137-143, 1999.
- [59] J. Lázaro, J. Arias, J. L. Martín, C. Cuadrado, A. Astarloa, "Implementation of a modified Fuzzy C-Means clustering algorithm for real-time applications", Microprocessors and Microsystems, Special Issue on FPGAs: Case Studies in Computer Vision and Image Processing, Vol. 29, No. 8-9, pp. 375-380, November 2005.

- [60] Olaf Wolkenhauer, "Data Engineering: Fuzzy Mathematics in System Theory and Data Analysis", John Wiley & Sons, Inc., Hoboken, New Jersey, 2001.
- [61] S. J. Roberts, "Parametric and Non-Parametric Unsupervised Cluster Analysis", Pattern Recognition, Vol. 30, pp. 261-272, Feb. 1997.
- [62] Zoran Zivkovic and Ferdinand van der Heijden, "Efficient adaptive density estimation per image pixel for the task of background subtraction", Pattern Recognition Letters, Vol. 27, No. 7, pp. 773-780, 2006.
- [63] P. K. Sahoo, S. Soltani, A. K. C. Wong, Y. C. Chen, "A survey of thresholding techniques", Computer Vision, Graphics, and Image Processing, Vol. 41, No. 2, pp. 233-260, 1998.
- [64] G. H. Golub and C. F. Van Loan, "Matrix Computations", 3rd Edition, John Hopkins University Press, Baltimore, Maryland, 1996.
- [65] J. Gross and J. Yellen, "Graph Theory and Its Applications", CRC Press, Inc., Boca Raton, Florida, 1999.
- [66] Robin J. Wilson, "Introduction to Graph Theory", Pearson Education Limited, Edinburgh Gate, Harlow, England, 1996.
- [67] M. Ester, H. P. Kriegel, J. Sander, X. Xu, "A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise", In Proceedings of Second International Conference on Knowledge Discovery and Data Mining, Portland, Oregon, pp. 226-231, 1996.
- [68] X. Xu, M. Ester, H. P. Kriegel, J. Sander, "A distribution-based clustering algorithm for mining in largespatial databases", In Proceedings of 14th International Conference on Data Engineering, Orlando, Florida, pp. 324-331, 1998.
- [69] J. Sander, M. Ester, H. P. Kriegel, J. Sander, X. Xu, "Density-Based Clustering in Spatial Databases: The Algorithm GDBSCAN and Its Applications", Data Mining and Knowledge Discovery, Vol. 2, No 2, pp. 169 - 194, 1998.
- [70] W. Wang, J. Yang, R. Muntz, "STING: A Statistical Information Grid Approach to Spatial Data Mining", Twenty-Third International Conference on Very Large Data Bases, Athens, Greece, pp. 186-195, 1997.
- [71] R. Unnikrishnan and M. Hebert, "Measures of Similarity", Seventh IEEE Workshop on Applications of Computer Vision, January, pp. 394-400, 2005.
- [72] R. Unnikrishnan, C. Pantofaru, M. Hebert, "A Measure for Objective Evaluation of Image Segmentation Algorithms", Proceedings of the 2005 IEEE Conference on Computer Vision and Pattern Recognition (CVPR '05), Workshop on Empirical Evaluation Methods in Computer Vision, Vol. 3, pp. 34-41, June, 2005.

- [73] C. Pantofaru and M. Hebert, "Comparison of Image Segmentation Algorithms", tech. report CMU-RI-TR-05-40, Robotics Institute, Carnegie Mellon University, September, 2005.
- [74] D. Martin, C. Fowlkes, D. Tal, J. Malik, "A Database of Human Segmented Natural Images and its Application to Evaluating Segmentation Algorithms and Measuring Ecological Statistics", Proc. 8th Int'l Conf. Computer Vision, Vol. 2, pp. 416-423, July 2001.
- [75] D. Martin, "An Empirical Approach to Gruping and Segmentation", Ph.D. dissertation, University of California, Berkeley, EECS Department, 2003.
- [76] Q. Huang, B. Dom, "Quantitative methods of evaluating image segmentation", International Conference on Image Processing (ICIP'95) - Vol. 3, pp. 53-56, 1995.
- [77] J. Cohen, "A coefficient of agreement for nominal scales", Educational and Psychological Measurement, pp. 37-46, 1960.
- [78] W. M. Rand, "Objective criteria for the evaluation of clustering methods", Journal of the American Statistical Association, Vol. 66, pp. 846-850, 1971.
- [79] M. D. Heath, S. Sarkar, T. Sanocki, K. W. Bowyer, "Robust Visual Method for Assessing the Relative Performance of Edge-Detection Algorithms", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 19, no. 12, pp. 1338-1359, Dec. 1997.
- [80] I. Slapničar, "Višeprocesorsko računanje", skripta, FESB, Split, 2005. (u izradi)
- [81] D. Jakobović, M. Golub, "Paralelno programiranje u raspodijeljenim sustavima", skripta, FER, Zagreb, 2007.
- [82] I. Foster, "Designing and Building Parallel Programs", Addison-Wesley Publishing Company, Inc., Boston, Massachusetts, USA, 1995.
- [83] Gene H. Golub, James M. Ortega, "Scientific Computing: An Introduction with Parallel Computing", Academic Press Inc., San Diego, California, 1993.
- [84] A. Gerbessiotis, D. Lecomber, C. Siniolakis, K. Sujithan, "PRAM Programming: Theory vs. Practice", In Proceedings of 6th Euromicro Workshop on Parallel and Distributed Processing, Madrid, Spain, pp. 164-170, Jan. 1998.
- [85] D. R. Ulm, M. Scherger, "Stream PRAM", 19th IEEE International Parallel and Distributed Processing Symposium (IPDPS'05) - Workshop 14, Denver, Colorado, April 2005.
- [86] E. Kuhrt, T. Behnke, H. Jahn, H. Hetzheim, J. Knollenberg, V. Mertens, G. Schlotzhauer An Automatic Early Warning System for Forest Fires, Annals of Burns and Fire Disasters, Vol. 14, No. 3, September 2001

- [87] R. Collins, A. Lipton, T. Kanade, H. Fujiyoshi, D. Duggins, Y. Tsin, D. Tolliver, N. Enomoto, and O. Hasegawa, "A system for video surveillance and monitoring", VSAM final report: The Robotics Institue, Carnegie Mellon University, CMU-RI-TR-00-12, 2000.
- [88] D. Stipaničev, T. Vuko, D. Krstinić, M. Štula, Lj. Bodrožić, "Forest Fire Protection by Advanced Video Detection System - Croatian Experiences", Third TIEMS Workshop - Improvement of Disaster Management System, Trogir, Sept. 26 - 27, 2006.
- [89] Lj. Bodrožić, D. Stipaničev, D. Krstinic, "Data fusion in observer networks", MASS07, The 4th IEEE International Conference on Mobile Ad-hoc and Sensor Systems, Pisa, Italy, October 8-11, 2007.